

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Matija Kušmišević**

Zagreb, 2016.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Predrag Čosić, dipl. ing.

Student:

Matija Kušmišević


Zagreb, 2016.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se svojoj obitelji na podršci i razumijevanju iskazanom tijekom studiranja.

Posebno bih se zahvalio mentoru prof. dr. sc. Predragu Ćosiću na velikom razumijevanju, strpljenju, savjetima te posvećenom vremenu i trudu prilikom izrade završnog rada.

Matija Kušmišević



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite

Povjerenstvo za završne ispite studija strojarstva za smjerove:

proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo materijala i mehatronika i robotika

Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje
Datum 24-02-2016 Prilog
Klasa: 602-04/16-6/3
Ur.broj: 15-1403-16-68

## ZAVRŠNI ZADATAK

Student: **Matija Kušmišević**

Mat. br.: 0035191327

Naslov rada na hrvatskom jeziku: **Potpora odlučivanju kod razrade projekta "Car Sharing"**

Naslov rada na engleskom jeziku: **Decision Support in Project Development for Car Sharing**

Opis zadatka:

U razradi projekta "Car Sharing" razmotriti logističke, tehnološke, proizvodne i financijske kriterije. U radu opisati značaj pojma "Car Sharing" kao dio koncepta Smart City. Smart City je i rezultat ekološkog pristupa, kako prometu u urbanim sredinama tako i ekološkom pristupu proizvodnji te LCA proizvoda. Opisati sustav višekriterijalnog optimiranja za potporu i odlučivanje AHP metodom (analitičko hijerarhijski proces) u softverskoj aplikaciji "Expert Choice". Primijeniti navedeni softver za odabir marke električnih automobila temeljem postavljenih kriterija, značajki električnih vozila te postavljenih ograničenja.

Zadatak zadan:

25. studenog 2015.

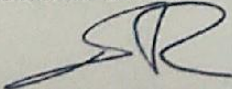
Rok predaje rada:

1. rok: 25. veljače 2016.
2. rok (izvanredni): 20. lipnja 2016.
3. rok: 17. rujna 2016.

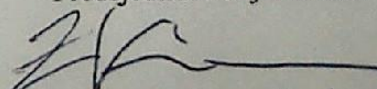
Predviđeni datumi obrane:

1. rok: 29.2., 02. i 03.03. 2016.
2. rok (izvanredni): 30. 06. 2016.
3. rok: 19., 20. i 21. 09. 2016.

Zadatak zadao:

  
Prof.dr.sc. Predrag Čosić

Predsjednik Povjerenstva:

  
Prof. dr. sc. Zoran Kunica

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	III
POPIS TABLICA.....	IV
POPIS KRATICA .....	V
POPIS OZNAKA .....	VI
SAŽETAK.....	VII
SUMMARY .....	VIII
1. UVOD.....	1
2. PROBLEM VIŠEKRITERIJSKOG ODLUČIVANJA .....	2
2.1. Sustavi za potporu pri odlučivanju - DSS .....	3
3. AHP METODA .....	5
3.1. Strukturiranje problema .....	6
3.2. Određivanje najznačajnijeg kriterija i alternative .....	7
3.3. Prednosti i nedostaci AHP metode .....	11
3.3.1. Prednosti .....	11
3.3.2. Nedostaci .....	12
4. PAMETNI GRAD .....	13
4.1. Car sharing .....	13
4.2. Implementacija Car sharing usluge.....	15
4.3. Električni automobil.....	16
4.3.1. Električni motor.....	18
4.3.2. Kontroler motora i izmjenjivač .....	18
4.3.3. Punjač u vozilu.....	18
4.3.3.1. Načini punjenja .....	19
4.4. Vrste baterija .....	21
5. PRIMJENA AHP METODE .....	23
5.1. Kriteriji.....	23
5.1.1. Domet.....	23
5.1.2. Baterija.....	24
5.1.3. Snaga motora .....	24

---

5.1.4. Okretni moment .....	25
5.1.5. Potrošnja .....	25
5.1.6. Jamstvo .....	26
5.1.7. Troškovi .....	26
5.2. Softver Expert Choice .....	29
6. IZBOR ELEKTRIČNOG AUTOMOBILA .....	30
6.1. Rezultati AHP metode u Expert Choiceu .....	32
6.2. Konačni odabir .....	36
7. AUTOMOBILSKA INDUSTRIJA U REPUBLICI HRVATSKOJ .....	37
8. ZAKLJUČAK.....	39
LITERATURA.....	40
PRILOZI.....	42

## POPIS SLIKA

Slika 3.1. Strukturiranje problema AHP metod [8] .....	6
Slika 3.2. Prikaz Saatyveve skale [7] .....	8
Slika 3.3. Prikaz usporedbe kriterija [7] .....	8
Slika 3.4. Matrica A [9] .....	9
Slika 3.5. Matrica X [9] .....	9
Slika 3.6. Slučajni indeks konzistencije RI [9].....	11
Slika 4.1. Usporedba učinkovitosti konvencionalnog i el.automobila[16].....	17
Slika 4.2. Prikaz sheme električnog automobila [16].....	19
Slika 6.1. Prikaz hijerarhijskog modela.....	30
Slika 6.2. Prikaz rezultata odabira .....	32
Slika 6.3. Poredak kriterija prema važnosti .....	32
Slika 6.4. Prikaz odnosa kriterija.....	33
Slika 6.5. Prikaz minimiziranja vrijednosti kriterija.....	33
Slika 6.6. Unošenje minimizirane vrijednosti kriterija.....	34
Slika 6.7. Prikaz postupka rangiranja alternativa .....	34
Slika 6.8. Analiza dobivenih rezultata .....	35
Slika 6.9. Analiza s promijenjenim kriterijima.....	35

**POPIS TABLICA**

Tablica 5.1.	Prikaz alternativa i kriterija .....	27
Tablica 5.2.	Prikaz električnih automobila .....	28
Tablica 6.1.	Proračun B/T .....	36
Tablica 7.1.	Primjer tvrki iz RH koje sudjeluju u autoindustriji .....	38



## POPIS KRATICA

AC - *Alternating current* – Izmjenična struja

AHP - *Analytic hierarchy process* – Analitički hijerarhijski proces

BMS - *battery management system* – Sustav upravljanja baterijom

DC – *Direct current* – Istosmjerna struja

DSS – *Decision Support System* – Podrška pri donošenju odluke

MCDA - *Multiple-criteria decision aid* - Podrška višekriterijskog odlučivanja

## POPIS OZNAKA

Oznaka	Jedinica	Opis
$CI = \frac{\lambda_{max} - n}{n - 1}$	-	Indeks konzistentnosti
n	-	Broj kriterija
$\lambda_{max}$	-	Konstanta za izračun indeksa konzistentnosti
RI	-	Slučajni indeks konzistentnosti
$CR = \frac{CI}{RI}$	-	Omjer konzistentnosti
L	km	Duljina
P	W	Snaga
I	A	Jakost struje
U	V	Napon
m	kg	Masa
M	Nm	Moment
n	1/min	Broj okretaja
T	kn	Troškovi
B	-	Benefiti (kvantitativno)

## SAŽETAK

U ovom radu opisan je postupak odabira električnog automobila za uslugu "Car Sharing" kao dio koncepta pametnog grada primjenom analitičkog hijerarhijskog procesa (AHP metode) na temelju kojeg radi i softverska podrška Expert Choice. Opisan je postupak i matematički model analitičkog hijerarhijskog procesa te su prikazani njegove prednosti i nedostatci.

Implementacija usluge Car Sharing je kompleksan projekt koji zahtjeva detaljnu analizu svih segmenata, a izbor električnog automobila je najvažniji tehnički i financijski dio cijelog projekta.

Ključne riječi: podrška pri donošenju odluke, analitički hijerarhijski proces, Car Sharing, pametni grad

## **SUMMARY**

This paper describes a procedure of selection electric car for the service "Car Sharing" as a part of concept of "Smart City", using the Analitic Hierarchy Process (AHP method) implemented in Expert Choice program. The procedure and mathematical model of AHP method is also described with its advantages and disadvantages.

The implementation of Car Sharing service is a complex project which require detailed analysis of all segments and choosing an electric car is the most important tehcnical and financial part of the project.

Key words: Decision Support System, Analitic Hierarchy Process, Car Sharing, Smart City

## 1. UVOD

Donošenje odluke je zahtjevan proces koji nosi veliku odgovornost, a posljedice donešene odluke mogu biti beznačajne, ali mogu imati i jako veliki utjecaj. Ponekad je teško donijeti odluku i za najjednostavnije probleme što predstavlja temelj razvijanja raznih matematičkih metoda koje bi trebale pomoći pri rješavanju kompleksnih problema. Problem je definiran ograničenjima koji predstavljaju kriterije.

Pomoć pri donošenju kompleksnih odluka je analitički hijerarhijski proces koji na matematičkom modelu donosi odluku. Temelj takve metode je definiranje i analiza svih ograničenja i kriterija. Ovakav model donošenja odluke je rasprostranjen u mnogim granama ljudskog djelovanja gdje je donešena odluka od velike važnosti za određeni projekt. Tržište je nepredvidiva okolina i ponekad je teško donijeti objektivnu odluku pa se zbog toga ponekad koriste metode statistike, predviđanja i vjerojatnosti. Predviđanje okoline i tržišta je tehnika koja pomaže rukovodstvu projekta da predvidi smjer u kojem tržište napreduje, analizirajući podatke iz prošlosti i sadašnjosti te predviđajući trendove. Zasniva se na iskustvu, znanju i prosudbi grupe ljudi koja se koristi tom tehnikom. Znanstvene metode za donošenje odluka pokušavaju minimizirati utjecaj subjektivnosti prilikom rješavanja kompleksnih problema kako bi rezultat bio što je moguće bolji i neovisan o faktoru ljudske pogreške.

Nabava velikog broja automobila za usluge kao što su taksi, rent-a-car ili Car Sharing<sup>1</sup> je veliki tehnički i financijski projekt. Na tržištu postoji veliki broj alternativa i potrebno je donijeti pravilnu odluku koja će ispuniti sve zahtjeve. Važnost donošenja pravilne odluke se očituje u isplativnosti cijelog projekta. Pogrešna odluka donosi zastoje u normalnom funkcioniranju usluge što uzrokuje gubitke ili veće početne troškove koji se mogu izbjeći pravilnom odlukom. Detaljna analiza kriterija i alternativa smanjuje utjecaj pogreške prilikom donošenja odluke pa je važno da donositelj odluke bude upoznat sa svim mogućim čimbenicima koji utječu na konačnu odluku.

U ovom radu će biti prikazan proces donošenja odluke izbora automobila za uslugu Car Sharing pomoću analitički hijerarhijskog procesa te sve prednosti i nedostaci koje takva metoda donosi.

---

<sup>1</sup> Car Sharing – usluga iznajmljivanja automobila u urbanim sredinama na kratko vrijeme kao dio koncepta pametni grad

## 2. PROBLEM VIŠEKRITERIJSKOG ODLUČIVANJA

Donošenje odluke je problem koji se javlja u gotovo svakoj djelatnosti. Problem odlučivanja se svodi na proces odabira jedne ili više alternativa koje su poznate donositelju odluke u svrhu poboljšanja procesa, tj. postizanja cilja. Važno je da je donositelj odluke upoznat sa svim ograničenjima koje proces postizanja cilja postavlja te da na osnovu tih kriterija donese ispravnu odluku. Kriteriji su najčešće konfliktni što predstavlja dodatno ograničenje prilikom objektivnog razmatranja cijelog problema. Rezultat procesa donošenja odluke je rješenje koje je u tom trenutku i u zadanim uvjetima najbolje što alternative pružaju. Ponekad je odluku lako donijeti ako postoji mali broj kriterija koji pri tome nisu konfliktni, ali najčešće u složenim organizacijama i sustavima donošenje odluke je kompleksan proces. Za jednostavnije i brže rješavanje problema potrebno je da donositelj odluke dobro poznaje kriterije na osnovu kojih se i donosi odluku. Kako uspjeh cijelog sustava ovisi o konačno donešenoj odluci, tako se razvijaju i metode koje bi pospješile proces odlučivanja.

Podrška višekriterijskog odlučivanja (eng. *Multiple-criteria decision aid - MCDA*) je znanstveno područje koje se bavi razvijanjem metodologije i metoda kojima se donositeljima odluke pomaže pri odlučivanju u kompleksnim situacijama koje podrazumijevaju postojanje više konfliktnih ciljeva, odnosno kriterija [1]. Prije raširene upotrebe računala, MCDA metodom su se koristili analitičari koji su pomagali u procesu donošenja odluke. Razvojem računala stvara se mogućnost programske potpore odlučivanja i demokratizira se primjena metoda MDCA. Razvijaju se sustavi za potporu pri odlučivanju (eng. *decision support system – DSS*) u kojima su implementirane metode višekriterijske analize.

Analitičar ili DSS sustav daje donositelju odluke mogućnost za odabir rješenja uz pomoć odgovarajućeg algoritma ili metode, a na temelju informacija danih od strane donositelja odluke. Nakon što se prikupe svi relevantni podaci od donositelja odluke, sustav daje prijedlog rješenja. Međutim, nužno je donositelju odluke prepustiti konačni odabir, odnosno dati mu mogućnost intervencije.

Kako opća podjela metoda višekriterijskog odlučivanja ne postoji, metode se dijele prema određenim kriterijima. Tako postoje podjele prema načinu uključivanja donositelja odluke u proces odlučivanja, prema klasama problema koji se rješavaju pomoću tih metoda, prema postupku rješavanja i ostalim sličnim kriterijima[2].

Obzirom na trenutak u kojem donositelj odluke može intervenirati postoje tri kategorije metoda [1]:

- *a priori metode* – donositelj odluke intervenira prije samog procesa na način da osigurana neke potrebne podatke, kao što su na primjer, težine kriterija.
- *a posteriori metode* – metode koje omogućavaju donositelju odluke da iz skupa zadovoljavajućih rješenja odabere ono koje njemu najbolje odgovara.
- *interaktivne metode* - to su metode koje omogućavaju donositelju odluke da posreduje tijekom pronalaženja rješenja. U njima je proces iterativan. Svaka iteracija osigurava donositelju odluke neko rješenje koje ne mora nužno biti i najbolje. Tada donositelj odluke daje potrebnim parametrima neke nove vrijednosti i tako usmjerava proces dalje.

Razvijanje metoda i sustava za podršku pri višekriterijskom odlučivanju je nužno jer se na taj način optimizira cijeli proces i sustav. Pri analizi kriterija i alternativa i rangiranju njihove važnosti primjenjuju se razni modeli koji pomažu pri rješavanju nekog problema. Dinamična okolina i timski rad pospješuju svaki proces dajući mu objektivnost i više ideja iz kojih se može pronaći najbolje rješenje. Ponekad je teško sagledati i razmotriti cijeli problem objektivno te se u takvim slučajevima primjenjuju metode koje ubrzavaju i daju najbolje moguće rješenje u tome trenutku.

Jedna od popularnih metoda kao pomoć pri odlučivanju je "Brainstorming". To je metoda s kojom se nastoji u što kraćem vremenu predložiti što više različitih ideja koja uvode u novi način razmišljanja u pronalaženju rješenja. Ideje bi namjerno trebale biti što šire i što neobičnije, a brzina je važan faktor, dinamičnost je jedna od glavnih karakteristika brainstorminga [3].

## **2.1. Sustavi za potporu pri odlučivanju - DSS**

Sustav za potporu pri odlučivanju je informacijski sustav podržan računalom koji se koriste kao pomoć pri odlučivanju na bilo kojoj razini upravljanja s naglaskom na odlučivanju kod slaboustruktuiranih i nestruktuiranih zadataka. DSS služi za organiziranje informacija, identifikaciju i dohvat informacija, analizu i transformaciju informacija, izbor modela odlučivanja i analizu dobivenih rezultata. Sadrži baze podataka pomoću kojih se lakše dolazi do informacija potrebnih donositelju odluke kako bi donio pravilan izbor. DSS je interaktivni sustav namijenjen da korisniku dade potrebne informacije iz kombinacije sirovih podataka koje sadrži u bazi, dokumenata i osobnih znanja ili poslovnih modela, za identificiranje i

rješavanje problema i donošenja odluka [4]. Takav sustav omogućava planiranje i kontrolu provođenja procesa, te fleksibilnost u odlučivanju i implementaciji odluka. Raspon implementacije sustava je od procesa s najjednostavnijim problemima do složenih sustava s kompleksnim problemima.

Iako je uvijek postojala potreba za pomoć pri donošenju odluka u svim područjima različitih djelatnosti, mogućnost za razvijanje ovakvih sustava paralelno se javila razvijanjem računalnih sustava i opreme [4]. Sustavi su se razvijali kako bi omogućili i olakšali samostalno donošenje što objektivnijih odluka, dinamičniji rad u timovima te bolju organizaciju hijerarhije poduzeća zbog sustava koji pomaže kod donošenju vrlo važnih i što je moguće racionalnijih odluka.

Uz sustave za potporu pri odlučivanju, mnogo je alata koji pospješuju proces donošenja odluke. Timski rad je bitan dio svakog procesa jer se time nastoji osigurati objektivnost odluke. Alati koji se koriste kako bi pospješili proces donošenja odluke temelje se na timskom radu i vizualizaciji problema. Primjer takvih metoda je SWOT<sup>2</sup> analiza, stablo odlučivanja, KANBAN<sup>3</sup>, prikaz podataka grafovima, dijagram tijeka događaja i mnoge druge. Svi se ti alati razvijaju kao potreba za donošenje objektivne odluke i usmjeravanje sustava prema uspješnom djelovanju. Svaki problem utječe na niz područja, stoga je važno je da se timovi sastoje od eksperata različitih znanja i iskustava kako bi se problem sagledao objektivno i kako bi odluka bila optimalna koliko to ograničenja dopuštaju.

Sustavi za potporu pri odlučivanju temelje se na znanstvenim metodama pa tako pored savjetnika, eksperata u timovima i svih drugih utjecajnih parametara, nastoje donositi odluke temeljem kvantitativnih kriterija i procjena. Jako je teško očekivati autonomne sustave koji će donositi kompleksne odluke bez utjecaja čovjeka i njegove procjene jer pored kvantitativnih kriterija, u realnoj okolini uvijek postoje kvalitativni kriteriji koje je potrebno interpretirati na način koji je za sada poznat samo čovjeku.

---

<sup>2</sup> SWOT analiza (Strengths, Weaknesses, Opportunities, Threats) – metoda analize situacije i položaja sustava

<sup>3</sup> KANBAN – sistematiziran raspored odvijanja akcija



### 3. AHP METODA

AHP metodu je razvio Thomas Saaty sedamdesetih godina dvadesetog stoljeća, a temelji se na matematici i psihologiji [5] te time čini snažnu podršku pri odlučivanju.

Analitički hijerarhijski proces (eng. *Analytic hierarchy process – AHP*) je metoda za odlučivanje koja se koristi kada je potrebno donijeti odluku između nekoliko alternativa koje se temelje na više atributa drugačije važnosti, a izražavaju se pomoću različitih skala. AHP metoda pomaže pri donošenju odluka na temelju kvantitativnih i kvalitativnih čimbenika. AHP metoda je najpopularnija i najčešće korištena metoda procesa odlučivanja kod rješavanja realnih problema te je tako našla svoju primjenu u inženjerstvu, industriji, politici, području obrane, marketingu te mnogim drugim područjima ljudskog djelovanja. Pomaže kod donošenja odluke kod kompleksnih problema čije elemente čine ciljevi, kriteriji, podkriteriji i alternative [6].

AHP metoda je snažan alat koji se koristi kod problema koji zahtjeva objektivnu prosudbu pri donošenju odluke pri čemu na temelju matematičke podloge daje rezultat. Dobiveni rezultat predstavlja znanstveni pristup rješavanju problema odabira. Zbog opsežnosti i točnosti samog procesa odabira, potrebno je provesti istraživanje koje uključuje odabir i analizu kriterija, ujedno i najznačajni dio hijerarhijskog modela pri odabiru alternative. Kvalitetna obrada atributa kriterija je potrebna zbog kasnijeg ponderiranja kriterija prema važnosti za postizanje cilja.

AHP metoda se zasniva na četiri aksioma [6]:

1. Aksiom *reciprocnosti*. Ako je element A  $n$  puta značajniji od elementa B, tada je element B  $1/n$  puta značajniji od elementa A.
2. Aksiom *homogenosti*. Usporedba ima smisla jedino ako su elementi usporedivi - npr. ne može se uspoređivati težina komarca i težina slona.
3. Aksiom *zavisnosti*. Dozvoljava se usporedba među grupom elemenata jednog nivoa u odnosu na element višeg nivoa, tj. usporedbe na nižem nivou zavise od elementa višeg nivoa.
4. Aksiom *očekivanja*. Svaka promjena u strukturi hijerarhije zahtjeva ponovno računanje prioriteta u novoj hijerarhiji.


AHP metoda sastoji se od *sljedećih faza* [7]:

- Strukturiranje problema
- Određivanje najznačajnijeg kriterija
- Određivanje najznačajnije alternative
- Određivanje konačnog rješenja

### 3.1. Strukturiranje problema

U prvoj fazi razvija se hijerarhijski model problema odlučivanja u sljedeće razine [7]:

- Cilj
- Kriteriji
- Podkriteriji
- Alternative



Slika 3.1. Strukturiranje problema AHP metod [8]

Tako strukturiran model predstavlja temelj procesa donošenja odluke. Jasno je u razinama prikazana zavisnost cilja procesa o kriterijima i podkriterijima koji čine najbitniji dio cijele strukture. Definiranjem cilja, određivanjem kriterija i podkriterija te izabiranjem alternativa postaje jasnija slika kompleksnosti problema i važnosti upotrebe znanstvene metode pri

rješavanju problema odabira. Strukturiranjem problema završen je prvi korak donošenja odluke pomoću AHP metode.

### **3.2. Određivanje najznačajnijeg kriterija i alternative**

Na svakoj razini hijerarhijske strukture u parovima se međusobno uspoređuju elementi te strukture, pri čemu se preferencije donositelja odluke izražavaju uz pomoć Saatyve skale relativne važnosti [7].

Skala ima 5 stupnjeva i 4 međustupnja verbalno opisanih intenziteta i odgovarajuće numeričke vrijednosti u rasponu od 1-9 što prikazuje Slika 3.2.

Kriteriji mogu biti kvantitativni ili kvalitativni. Kvalitativne kriterije je moguće vrednovati samo na temelju iskustva i prethodnog znanja što daje dozu subjektivnosti procesa odlučivanja. Na taj način izravno se utječe i na rezultat odlučivanja. Prije samog procesa, potrebna je detaljna analiza svakog elementa hijerarhijske strukture kako bi se donijela pravilna odluka tijekom svake faze rješavanja problema. Detaljna analiza kriterija i alternativa je potrebna jer se na temelju tih podataka ti elementi uspoređuju. Nedovoljnim poznavanjem važnosti određenog kriterija ili manjak podataka o alternativni može dovesti do rezultata koji nije objektivno najpovoljniji i najbolji izbor.

Kvantitativne kriterije je lako usporediti zbog njihove prirode pa procesa odlučivanja postaje objektivniji, a utjecaj donositelja odluke je eliminiran. Kvalitativne kriterije je teže uspoređivati i vrednovati te pri tome ostati objektivni zbog subjektivnog dojma donositelja odluke. Neki primjeri kvalitativni kriteriji su dizajn, pouzdanost, fleksibilnost dok su kvantitativni kriteriji potrošnja, domet, cijena i sl.

Ocjena prioriteta	Opisna ocjena prioriteta	
1	Jednaki prioritet	Equal
2	Jednaki do umjereni prioritet	Intermediate favors
3	Umjereni prioritet	Slightly favors
4	Umjereni do jaki prioritet	Intermediate favors
5	Jaki prioritet	Strongly favors
6	Jaki do vrlo jaki prioritet	Intermediate favors
7	Vrlo jaki prioritet	Very strong favors
8	Vrlo jaki do apsolutni prioritet	Intermediate favors
9	Apsolutni prioritet	Extreme favors

Slika 3.2. Prikaz Saatyjeve skale [7]

Kriteriji se međusobno uspoređuju i ocjenjuju pomoću Saatyjeve skale. (Slika 3.2.)



Slika 3.3. Prikaz usporedbe kriterija [7]

Proces uspoređivanja se izvodi pomoću brojčane skale pri čemu veći broj daje veću vrijednost kriterija ili alternative. (Slika 3.3.)

Rezultati uspoređivanja elemenata na nekoj od razina hijerarhije smještaju se u određene matrice usporedbe. Npr., ako se međusobno uspoređi  $n$  elemenata u odnosu na odgovarajući element na neposredno višem nivou hijerarhije, tada se pri usporedbi elementa  $i$  u odnosu na element  $j$  putem Saatyjeve skale određuje numerički koeficijent  $a_{ij}$  i smješta na odgovarajuću poziciju u matrici  $A$  (Slika 3.4.). [9]

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdot & \cdot & a_{1n} \\ a_{21} & a_{22} & \cdot & \cdot & a_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ a_{n1} & a_{n2} & \cdot & \cdot & a_{nn} \end{bmatrix}$$

Slika 3.4. Matrica A [9]

Recipročna vrijednost rezultata uspoređivanja se smješta na poziciju  $a_{ji}$  da bi se sačuvala konzistentnost usporedbe. Npr., ako je element 1 neznatno favoriziran u odnosu na element 2, na mjestu  $a_{12}$  matrice A bio bi broj 5, a na mjestu  $a_{21}$  recipročna vrijednost 1/5.

Smisao matrice usporedbe najbolje se može razumjeti iz sljedećeg. U "savršenom svijetu" što je identično konzistentnom vrednovanju, matrica A, u koju se smještaju rezultati uspoređivanja bila bi ista kao matrica X (Slika 3.5.). [9]

$$X = \begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \dots & \frac{w_2}{w_n} \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & \frac{w_n}{w_n} \end{bmatrix}$$

Slika 3.5. Matrica X [9]

gdje  $w_i$  predstavlja relativni težinski koeficijent elementa  $i$ .

U sljedećem koraku, definirana matrica usporedbe množi se sama sa sobom te nakon množenja matrica dobiva se nova matrica tkz. **1. iteracije** iz koje se određuje **1. vektor prioriteta**.

Nadalje **1. vektor** prioriteta određuje se tako da se sumira redove nove matrice, te normalizacijom sume redova dobiva se vektor prioriteta. Normalizacija se provodi da bi podaci bili uniformni i usporedivi.

Sljedeći korak je 2. iteracija tj. **nova matrica** koja se dobiva množenjem 1. iteracije same sa sobom, te iz nje se dobije **2. vektor prioriteta** sumiranjem i normalizacijom redova novonastale matrice.

Kada postoje dva vektora prioriteta izračunava se vektor razlike, te ako je njegov iznos zanemariv određuje se najznačajniji kriterij ili alternativa, a ako je iznos vektora razlike značajan, računa se nova iteraciju i novi vektor prioriteta te se ponovo traži vektor razlike. Ako u nekoliko sljedećih iteracija, iznos vektora razlike nije zanemariv postupak nije konzistentan. Postupak je objašnjen i prikazan u Prilogu II.

### 1.1. Određivanje konačnog rješenja

Nakon što je određen *vektor prioriteta alternativa* i *vektor prioriteta kriterija*, ta dva vektora se množe i dobiva se **vektor prioriteta cilja**. Iz vektora prioriteta cilja s obzirom na razmatrane kriterije i alternative dobiva se **rješenje složenog problema**. **Najbolja alternativa** uz postavljene uvjete je ona koja je poprimila **najveću vrijednost u vektoru prioriteta cilja**.

### 1.2. Procjena konzistentnosti odlučivanja

AHP spada u popularne metode zato što ima sposobnost analiziranja i identificiranja nekonzistentnosti donositelja odluke u procesu uspoređivanja i vrednovanja elemenata hijerarhije. Čovjek je rijetko konzistentan pri procjenjivanju vrijednosti ili kvalitativnih značajki elemenata u hijerarhiji. AHP na određen način ublažava taj problem tako što **računa omjer konzistencije** i o tome obavještava donositelja odluke.

Kada bi postojala mogućnost da se precizno odrede vrijednosti težinskih koeficijenata svih elemenata koji se međusobno uspoređuju na nekom od nivoa hijerarhije, svojstvene vrijednosti matrice bile bi potpuno konzistentne. Međutim ako npr. svojstvo A je važnije od B, a svojstvo B važnije od C, onda svojstvo A mora biti važnije od C, jer je inače nekonzistentnost u rješavanju problema i smanjuje se pouzdanost rezultata.

Da bi se procijenila konzistentnost odlučivanja potrebno je izračunati **mjeru konzistencije** tj. indeks konzistencije  $CI$ , a računa se prema sljedećem izrazu:

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (1)$$

gdje je:  $\lambda_{max}$  – najveća svojstvena vrijednost

$n$  – broj kriterija

Slučajni indeks konzistentnosti  $RI$  ovisi o redu matrice, a dobiven je tako što je prof. Saaty za svaku matricu veličine  $n$  generirao nasumične matrice te izračunao njihovu srednju vrijednost  $CI$  i nazvao je **slučajni indeks konzistencije  $RI$**  (Slika 3.6.).

<b>n</b>	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
<b>RI</b>	0.00	0.00	0.58	0.90	1.12	1.24	1.32	1.41	1.45	1.49	1.51	1.48	1.56	1.57	1.59

**Slika 3.6. Slučajni indeks konzistencije  $RI$  [9]**

Omjer konzistencije  $CR$  je omjer indeksa  $CI$  i indeksa  $RI$

$$CR = \frac{CI}{RI} \quad (2)$$

Ako je stupanj konzistentnosti  $CR$  manji od 0,10, rezultat se smatra dovoljno točan i nema potrebe korigirati usporedbe i ponavljati proračun. Ako je **stupanj konzistentnosti  $CR$  veći od 0,10**, rezultat bi trebalo ponovo analizirati i ustanoviti razloge nekonzistentnosti, ukloniti ih, te ako se nakon ponavljanja postupka u nekoliko koraka, stupanj konzistentnosti  $CR$  ne smanji ispod granice od 0,10, **sve rezultate treba odbaciti i ponoviti cijeli postupak ispočetka**. [9]

### 3.3. Prednosti i nedostaci AHP metode

AHP metoda je najrasprostranjenija metoda pri procesu rješavanja kompleksnih problema odlučivanja zbog boljih uporabnih karakteristika, ali i ta metoda ima neke svoje nedostatke.

#### 3.3.1. Prednosti

AHP metoda ima niz prednosti[6]:

- AHP strukturira problem odlučivanja i uspješno simulira proces donošenja odluka od definiranja cilja, kriterija i alternativa, do uspoređivanja kriterija i alternativa u parovima i dobivanja rezultata
- Integrira kvantitativne i kvalitativne faktore u odlučivanju
- Provjerava konzistentnost
- Uspoređivanje u parovima što smanjuje mogućnost pogreške

- 
- Kod grupnog odlučivanja poboljšana komunikacija između članova i bolje upoznavanje sa samim problemom
  - Kratko vrijeme donošenja odluke
  - Manji troškovi procesa donošenja odluke
  - Postojanje kvalitetnih programskih alata (npr. *Expert Choice*, *MakeItRational*, *Priority Estimation Tool*)

### 3.3.2. Nedostatci

AHP ima i neke nedostatke koji se daljnim istraživanjima nastoje potpuno eliminirati ili barem minimalizirati njihov negativan utjecaj na proces donošenja odluke [6]:

- Nedovoljno velika skala pri uspoređivanju kriterija ili alternativa za neke specifične probleme
- Velik broj potrebnih uspoređivanja
- Teško postizanje prihvatljivog omjera konzistentnosti
- Nisu dozvoljene neusporedive alternative
- Velik utjecaj čovjeka kod odabira kriterija i njihove važnosti.



## 4. PAMETNI GRAD

Pametni grad (eng. *Smart City*) se može najjednostavnije definirati kao sustav koji koristi digitalne i komunikacijske tehnologije da zadovolji sve potrebe svojih građana te unaprijedi učinkovitost gradskih usluga. Takav sustav uz to što smanjuje troškove i potrošnju energije, stvara čišći okoliš i podiže životni standard stanovnika. Pametni grad je koncept koji integrira sve funkcije javnih usluga poput rasvjete, prometa, upravljanja otpadom i energijom te na taj način povećava njihovu efikasnost, smanjuje troškove električne energije, ubrzava komunikaciju među spomenutim podsustavima i znatno smanjuje emisije dušičnih spojeva. Većina svjetski gradova nastoji podići standard i kvalitetu života stanovnika te s tim ciljem uvodi i različite koncepte i sustave koji bi pridonijeli razvitku pametnog grada. Jedan od takvih koncepata je i usluga Car Sharing koja će se detaljnije obraditi u ovome radu.

### 4.1. Car sharing

"Car sharing" je usluga koja pripada konceptu pametnog grada, a podrazumijeva dijeljenje automobila između korisnika na kratko vrijeme [10]. Usluga koja postaje sve popularnija u razvijenim zemljama svijeta zahtjeva složen tehnički sustav te detaljnu razradu kako bi implementacija bila uspješna. U vrijeme kad je sve više automobila na gradskim prometnicama i prometne gužve su neizbježne, javlja se potreba za rješavanjem tog problema. Gradska središta su postala prenapučena vozilima što predstavlja problem i regulacije prometa i kvalitete života građana. Drugi problem je svakako svakodnevno zagađenje okoliša putem ispušnih plinova iz konvencionalnih automobila s motorom s unutarnjim izgaranjem. Iako proizvođači automobila sve više razvijaju ekološki prihvatljivije motore broj vozila svakodnevno raste, a time i količina štetnih plinova koje ta vozila ispuštaju u atmosferu. Vođeni tom činjenicom, mnogi svjetski gradovi uvode zabranu prometovanja u nekim gradskim dijelovima te proglašavaju pješačke zone, ili čak poduzimaju radikalne mjere poput dana bez automobila, a sve u svrhu smanjenja zagađenja.

Jedno od rješenja velikog zagađenja uzrokovanog vozilima s motorima s unutarnjim izgaranjem je učestalije korištenje javnog prijevoza. Mnoge države i gradske vlasti ulažu sve više novca u razvoj javnog prometa kako bi postao efikasan i dostojna zamjena osobnim automobilima. Veliki utjecaj na rješavanje ovog problema ima stanovništvo koje još uvijek nije dovoljno svjesno problema koje ih okružuje te na prvo mjesto stavljaju osobno

zadovoljstvo i interese. Problem javnog prijevoza je što ne pruža dovoljno fleksibilnosti i udobnosti koju potencijalni korisnici zahtijevaju. Rješenje koje zadovoljava sve navedene zahtjeve je usluga Car Sharing.

Car Sharing je usluga koja korisniku pruža mobilnost, fleksibilnost, udobnost, a ujedno je i ekološki prihvatljiva. Takav koncept zahtjeva modernog, ekološki osvještenog korisnika koji shvaća nedostatke današnjeg prometa i učinka na atmosferu, a i na kvalitetu života. Sam koncept pametnog grada podrazumijeva stanovnika, a time i korisnika svih usluga, kao osobu koja je u suživotu s tehnologijom, što objedinjuje pojam "Internet of things"<sup>4</sup>.

Koncept je stvoren na ideji da korisnici ne posjeduju osobni automobil i na taj način izravno povećavaju broj automobila na prometnicama i povećavaju zagađenje nego da koriste platformu automobila koji su na raspolaganju svima u svakom trenutku. Automobili bi bili raspoređeni na određenom području, a korisnik bi putem aplikacije na svom pametnom uređaju u svakom trenutku mogao vidjeti dostupnost vozila. Ideja je da se platforma vozila sastoji od električnih automobila kako bi se i na taj način što više čuvao okoliš. Putem aplikacije bi se vidjelo stanje vozila te bi korisnik mogao isplanirati svoj put prema dostupnim informacijama. Vozilo bi se otključavalo pomoću aplikacije koju korisnik posjeduje te nakon ulaska u vozilo i prijave krenula bi naplata korištenja usluge. Prije prvog korištenja uslugom korisnik se treba registrirati pri čemu ostavlja svoje podatke pomoću kojih se može utvrditi identitet i ovlaštenost upravljanja vozilom, a i naplatiti uslugu. Naplata se vrši preko kreditne kartice, a naplaćuje se vrijeme provedeno u vozilu. Nakon prestanka korištenja automobila korisnik ostavlja automobil na javnom parkiralištu kako bi vozilo bilo dostupno drugim korisnicima. Svakom korisniku su dostupne informacije o vrsti i marki vozila, napunjenosti baterije, očuvanosti, stanju unutrašnjosti i sl. Usluga omogućava i jeftinije korištenje ako korisnik automobil ostavi na mjestu gdje se može nadopuniti baterija [11].

Neka istraživanja pokazuju da *jedno vozilo Car Sharinga uspješno zamjenjuje petnaest vozila u privatnom vlasništvu* što predstavlja znatno smanjenje zatrpanosti gradskih prometnica, parkirališta, a i zagađenje okoliša [12]. Prednost usluge je i u tome što korisnik ne mora plaćati potrošak energije nego samo vrijeme korištenja usluge. Također, navodi se da je korištenje ovakve usluge isplativo za sve korisnike koji godišnje *s automobilom naprave manje od 8500 km* jer posjedovanje automobila osim uložih sredstava za kupnju iziskuje i

---

<sup>4</sup> eng. *Internet of things* – povezivanje uređaja putem interneta

troškove servisiranja, osiguranja, tehničkog pregleda, punjenja spremnika, plaćanja javnog parkirališta i sl. [13].

Istraživanje koje je provelo Tvrtka Citroen Savska (Zagreb) na tristotinjak ispitanik u trajanju od deset mjeseci pokazalo je da korisnici automobila u gradskoj vožnji dnevno provedu u prosjeku 56 minuta i tako prijeđu 26 km. Unutar navedenih brojki čak 64% ukupnih putovanja se odnosi na kraće rute s prijeđenih manje od deset kilometara [14]. Iako je istraživanje provedeno na malom uzorku dolazi se do nekih zaključaka kako bi postojanje usluge kao što je Car sharing pomoglo pri rješavanju problema gradskih gužvi i velike emisije štetnih plinova, ali i osobnog troška svakog pojedinca koji posjeduje osobni automobil. Nije poznato kako je upitnik izgledao pa je rezultate same ankete potrebno uzeti s oprezom.

Usluga Car Sharing omogućava mobilnost, fleksibilnosti i udobnost koju nudi osobni automobil, ali se pri tome i osvještano razmišlja o održivom razvoju gradova. Korisnicima se nudi vozilo koje zamjenjuje posjedovanje osobnog automobila, ali i izbjegavanje javnog prijevoza koje nudi mnoge nedostatke. Ovakav koncept postaje sve više raširen i prihvaćen širom svijeta te korisnici mijenjaju svoje navike i potrebe što poboljšava kvalitetu života svih [10].

#### **4.2. Implementacija Car sharing usluge**

Kao što je navedeno, usluge Car Sharinga rasprostranjene su u državama diljem svijeta pa se tako pojavljuju i u sve više europskih gradova. Stanovnici tih gradova prepoznaju prilike koje pružaju takve i slične usluge i sve više prihvaćaju "pametan", ekološki prijateljski način života. Car Sharing i slične usluge su rezultat pokreta zaštite okoliša i pokušaja rješavanja zatrpanosti gradskih prometnica. U koraku s drugim europskim i svjetskim gradovima, i Zagreb uskoro dobiva uslugu Car Sharinga.

U planu je implementirati uslugu u obliku 30 automobila od kojih deset čine električni automobili. Predviđeno je da električni automobili koriste postojeću infrastrukturu za punjenje koja bi trebala zadovoljiti sve potrebe tolikog broja električnih vozila. Iako nisu poznati svi detalji projekta, poznato je da bi električni automobil trebao biti Volkswagenov e-Up koji će biti razmatran i u radu kao jedna od alternativa. Uvjeti financiranja projekta nisu poznati pa tako nisu poznati ni kriteriji koji su postavljeni pri izboru automobila.

Prilikom izbora električnog automobila u svrhu ovoga rada neće se uzimati u obzir broj automobila jer projekt nije toliko detaljno razrađen. Također, zanemarit će se uvjeti financiranja i vraćanje uloženog kapitala jer je izbor automobila uzet samo kao primjer

moгуće primjene AHP metode. Kod detaljnije razrade cijelog projekta bilo bi potrebno uzeti u obzir i moguću popust na vozila ostvaren pregovaranjem zbog veće količine vozila, troškove osiguranja i održavanja, troškove zaposlenika, uvjete kredita/leasinga te mnoge druge čimbenike koji će se u ovom radu smatrati fiksnim za sve alternative te se neće uzimati u obzir. Kako je tema rada izbor električnog automobila, neće se uzimati u obzir ni cijena usluge.

Poznato je da bi cijena usluge kada se implementira u Grad Zagreb trebala iznositi 2,62 kn/min uz cijenu registracije od 150 kn. Ovakva cijena je viša od prosječnih cijena ostalih europskih gradova. Iako nema točnih podataka kada usluga kreće u rad, predviđa se da će to biti na proljeće ove godine.

### **4.3. Električni automobil**

Električni automobili se idealno uklapaju u koncept Car Sharinga jer svojim karakteristikama ispunjava najbitniji uvjet – smanjenje emisije štetnih plinova.

Električni automobil je automobil pokretan elektromotorom koji crpi električnu energiju iz spremnika za pohranu energije, tj. baterija [15]. Razvoj električnih automobila se javlja krajem 19. i početkom 20. stoljeća, ali većim iskorištavanjem naftnih resursa dolazi do razvoja motora s unutarnjim izgaranjem te električni automobili odlaze u drugi plan. Nesigurno tržište naftnih derivata i sve manje prirodnih resursa dovodi do ponovnog razvoja električnih automobila pa danas na tržištu gotovo svaki proizvođač automobila razvija i inačicu električnog automobila. Tome je pridonijelo i pritisak nadnacionalnog EU organa koji kao dio strategije očuvanja i onako skromnih naftnih resursa nalaže razvijanje vozila na alternativne pogone. Tržište sve više zahtjeva uređaje i tehnologije koje su u skladu s održivim razvojem pa se tako razvijaju i vozila na alternativne izvore energije. Električni automobili prednjače u razvoju zbog svoje jednostavnosti. Sve više njihova kvaliteta je prepoznata i kod korisnika te je sve učestalije da se na prometnicama pojavljuju i električni automobili. Razvojem i svakodnevnim napretkom automobilske industrije i visoke tehnologije razvijat će se i električni automobili i njihove komponente što će dovesti do ravnopravnog položaja s automobilima s motorima s unutarnjim izgaranjem.


Prednosti električnih automobila u odnosu na konvencionalne automobile su:

1. tiši rad koji omogućava električni motor,
2. neispuštanje štetnih plinova,
3. ne troše energiju prilikom zaustavljanja nego dio čak i regeneriraju,

4. bolja iskoristivost motora,
5. jednostavnije održavanje,
6. manja cijena održavanja,
7. jeftinija energija,
8. veća pouzdanost motora i ostale opreme,
9. veća dostupnost energetske izvora (punjenje kod kuće),
10. poticaji za kupnju električnih vozila.

Nedostatci električnih vozila su:

1. ograničen kapacitet baterije,
2. vrijeme punjenja baterije,
3. nedostatak infrastrukture za punjenje,
4. manja snaga automobila,
5. dodatna oprema smanjuje trajanje baterije,
6. baterija zauzima velik prostor i povećava masu vozila,
7. opasnost od zapaljenja baterije prilikom oštećenja,
8. zagrijavanje baterije,
9. veća početna cijena,
10. visoka cijena baterije.



**Slika 4.1. Usporedba učinkovitosti konvencionalnog i el.automobila[16]**

Glavne komponente električnog automobila su [16]:

- električni motor,
- kontroler motora i izmjenjivač,
- punjač u vozilu,
- baterija za pohranu energije.

---

#### **4.3.1. Električni motor**


Električni motor služi za pretvorbu električne energije u mehanički rad. Prednosti električnog motora su minimalni gubici energije do 11% te jednostavna konstrukcija koja čini motor pouzdanijim i smanjuje troškove njegovog održavanja [16]. Elektromotorima se deklarira snaga koju mogu trajno isporučivati iako trenutna snaga može biti i deset puta veća što onda dovodi do toga da su elektromotori male nazivne snage. *Elektromotor od 15 kW* u startu može isporučiti i *60-70 kW snage* ako je tako podešen, ali nakon što ubrza snaga pada jer za održavanje brzine nije potrebno niti blizu onoliko koliko za pokretanje iz mjesta. Elektromotornom pogonu u prilog ide i veliki okretni moment koji je dostupan odmah za razliku od benzinskog ili dizelskog koji to postižu tek nakon što motor dosegne bar 3000 okretaja. *Zbog velikog okretnog momenta elektromotoru nije potreban ni mjenjač ili u nekim slučajevima da ali samo sa dvije brzine* [17].

#### **4.3.2. Kontroler motora i izmjenjivač**

Kontroler motora nadzire snagu, broj okretaja motora, položaj rotora motora te temperaturu motora [16]. U izmjenjivaču se istosmjerni napon baterije pretvara u izmjenični koji je potreban za pokretanje motora. Važan je dio sustava koji osigurava da motor dobije potrebnu energiju koja se pretvara u mehaničku te na taj način pogoni vozilo.

#### **4.3.3. Punjač u vozilu**

Koristi se za pretvorbu izmjeničnog napona mreže u istosmjerni napon baterije [16]. Trajanje punjenja baterije ovisi o *kapacitetu baterije i vrsti punjača*. Što je veći kapacitet baterije to će biti duže trajanje punjenja baterije. Vrsta punjača definira hoće li se baterija puniti s istosmjernom ili izmjeničnom strujom što izravno utječe na vrijeme trajanja punjenja. Ograničenja ovakvog uređaja je visoka cijena i zagrijavanje punjača što ograničava i snagu samog punjača pa se često upotrebljavaju sustavi za nadopunjavanje potrošene energije baterije s vanjskim punjačem koji bateriju vozila izravno puni s istosmjernom strujom.



**Slika 4.2. Prikaz sheme električnog automobila [16]**

#### 4.3.3.1. Načini punjenja

Prema standardu IEC 61851 definiraju se načini punjenja vozila i uvjeti pod kojima se obavlja punjenje. Također ovaj standard vodi i brigu o sigurnosti tijekom punjenja.

Nekoliko je vrsta punjenja definirana standardom IEC 61851-1[18]:

- **Mod 1** – sporo punjenje iz obične utičnice (jednofazne ili trofazne)
- **Mod 2** – sporo punjenje iz obične utičnice koja je nadopunjena sa zaštitnim elementom (npr. *Park & Charge* ili *PARVE* sistemi)
- **Mod 3** – sporo ili brzo punjenje koristeći specifičnu višepinsku utičnicu sa kontrolnim i zaštitnim funkcijama
- **Mod 4** – brzo punjenje koristeći specijalne izvedbe punjača i protokole punjenja kao što je **CHAdEMO** protokol.

Kod **Mod 1** načina punjenja električno se vozilo spaja na napojnu mrežu koristeći standardne AC utičnice ("šuko"-utičnice) koje su izvedene za struju iznosa 16 A i napon 250 jednofazno ili 480 V trofazno. Punjač (ispravljač) koji upravlja punjenjem baterije ugrađen je u vozilu. S automobilom dolazi potreban pribor za priključak do punionice. Ovaj način punjenja je jednostavan i izravan, iako je punjenje do stanja potpune napunjenosti baterije najčešće višesatno. U Mod 1 načinu punjenja postoji gornja granica snage punjenja, a struja punjenja

od 10 A se pokazuje kao najbolji kompromis. Pri ovoj struji punjenja i prosječnim iznosima kapaciteta baterija, potrebno je otprilike *10 sati za potpuno nadopunjavanje baterije vozila*.

Kod **Mod 2** način punjenja se električno vozilo spaja na napojnu mrežu koristeći standardne AC utičnice koje su izvedene za struju iznosa 32 A i napona 250 V jednofazno ili 480 V trofazno. Punjač koji upravlja punjenjem baterije ugrađen je u vozilu. S automobilom dolazi pribor za priključak do punionice. Ovo rješenje je *sigurnije od prijašnjeg* jer se koristi zaštitni uređaj diferencijalne struje (RCD sklopka) koji štiti od električnog udara. Baterija se puni većim strujama pa je vrijeme trajanja punjenja smanjeno na 4 do 6 sati. Zbog potrebe za posebnim priključnim kabelom **Mod 2** način je nešto skuplji od **Mod 1** načina punjenja.

**Mod 3** je način punjenja električnog vozila preko AC napojne mreže koristeći posebno razvijenu priključnu opremu s naglašenom ulogom upravljačke (engl. *control pilot*) funkcije, stalno spojene na AC izvor. Stanica na koju je priključeno vozilo ima unaprijed ugrađene zaštitne i upravljačke elemente poput regulatora snage punjenja, osigurača za prenaponsku i nadstrujnu zaštitu i RCD sklopke. Ovaj sustav i način punjenja omogućavaju paralelni rad punjača i ostalih kućanskih uređaja kao i izbor vremena punjenja vozila bez da su ugroženi standardi koji definiraju karakteristike instalacije. To je omogućeno komunikacijom sustava u automobilu i priključne stanice pomoću čega se regulira jakost struje, a time i vrijeme punjenja koje ovim načinom punjenja može iznositi oko 2 do 6 sati, ovisno o kapacitetu baterije.

**Mod 4** je način punjenja električnog vozila spojenog na AC mrežu preko vanjskog punjača gdje upravljačka (engl. *control pilot*) funkcija proširuje opremu stalno spojenu na AC izvor. Kod Mod 4 načina punjenja električna struja iz AC izvora se u vanjskom punjaču pretvara u DC struju. Kontrolne i zaštitne funkcije kao i priključni kabel se nalaze na strani punjača. Tip priključka izvedenog na vozilu osigurava da se samo odgovarajuće električno vozilo može priključiti na punjač. Upotrebom *DC brzog punjenja* je omogućeno punjenje strujama do 400 A (prema IEC 61851-1 standardu). Stanica je izvedena s regulatorom snage punjenja, osiguračem za prenaponsku i nadstrujnu zaštitu i RCD sklopkom što onemogućava zagrijavanje opreme prilikom punjenja te štiti od električnog udara. Elektrostаница s izvorom istosmjernog napona u pravilu može pomoću brzog punjača omogućiti *punjenje baterija automobile za 20-tak minuta*. Brzo punjenje ne utječe na vijek trajanja baterije jer je baterijski sustav zaštićen BMS sustavom koji sprječava bilo kakav negativan utjecaj. [16]



Za kućne instalacije i punjenje električnih automobila kod kuće su predviđeni Mod 1, Mod 2, Mod 3 dok je način punjenja putem Mod 4 načina namijenjen za javne punionice gdje korisnici mogu u kratko vremenu nadomijestiti potrošenu energiju. Na mjestima poput javnih garaža, parkirališta ili trgovačkih centara sve se više instaliraju punionice za električna vozila kako bi se općenito potaknulo ljude na korištenje električnih vozila i na taj način doprinijelo razvoju pametnih gradova i održivog razvoja. Takav način razvoja omogućava uspješnu implementaciju usluge kao što je Car Sharing jer takav koncept zahtjeva i prihvatljivu infrastrukturu kako bi cijeli projekt bio izvediv i uspješan.

Grad Zagreb trenutno posjeduje 29 javne punionice za električna vozila što predstavlja dovoljnu infrastrukturu za trenutni broj električnih vozila na tom području, ali sigurno će se taj broj i povećati kako će se povećavati i broj električnih vozila, a samim time i potreba za punionice [19].

#### 4.4. Vrste baterija

Baterija je jedan od glavnih elemenata električnih vozila. U bateriji je pohranjena kemijska energija koja se oslobađa kada je to potrebno kako bi se elektromotor pokretao. U osnovi se sastoji od katode, anode i elektrolita. Različite vrste baterija se razlikuju po materijalu od kojih su sagrađeni pojedini dijelovi baterije. Baterije se sastoje od jedne ili više ćelija koje mogu biti spojene u seriju kako bi davale veći napon. U slučaju automobilske baterije serija se može sastojati od stotina ćelija povezanih u seriju. Karakteristike baterije koje su važne za korisnika električnih automobila su gustoća električne energije i snaga baterije. [20]

Gustoća električne energije je mjera koja govori koliko energije baterija može pohraniti, a izražava se kao Wh/kg. Što više energije baterija može pohraniti, to će vijek ciklusa do ponovnog punjenja duže trajati.

Snaga energije je mjera koja iskazuje koliku količinu energije baterija može isporučiti u određenom trenutku. Važna je i jer pokazuje i koliko se brzo baterija može napuniti, a izražava se u W.

Neke vrste baterija koje se koriste u auto-moto industriji [20]:

**Olovne baterije** – koriste se kod automobila i kamiona za startanje motora, osvjetljenje i ostale električne funkcije. Relativno su jeftine, imaju veliku gustoću snage, ali relativno malu gustoću energije.

**Nikal metal hibridne baterije (NiMH)** – koriste se često u hibridnim automobilima i u svakodnevnoj primjeni u električnim aparatima poput fotoaparata, električnih četkica za zube

i sl. Imaju gotovo dvostruko veću energetska gustoću od olovnih baterija, ali snaga je ograničena veličinom.

**Litij - ionske baterije** – koriste se u laptopima i mobitelima te su najrasprostranije baterije koje se koriste za električna i hibridna vozila. Njihova gustoća energije i snage je nekoliko puta veća nego kod NiMH baterija te imaju veliku efikasnost ciklusa pražnjenja i punjenja. Tijekom njihovog korištenja kod električnih i hibridnih automobila potreban je sustav hlađenja jer otpuštaju veliku količinu topline te se s time mijenja i njezin kapacitet. Dodatni sustav hlađenja crpi snagu iz pogonskog elektromotora ili pak postoji zasebni elektromotor. Takav sustav smanjuje kapacitet baterije. Cijena litij - ionske baterije je visoka.

**Litij - polimer baterije** – pripada skupini litijskih baterija. Razlika od obične litij-ionske baterije je u elektrolitu koji je ovdje polimer. Forma nije uvjetovana kao cilindrična pa je lakša prilagodljivost oblika same baterije. Koristi se u nekim hibridnim vozilima.

**Litij - želježno fosfatne baterije** – vrsta litijske baterije koja kao katodu koristi željezov fosfat. Prednost ovakve baterije je smanjena emisija topline i nezapaljivost prilikom mehaničkog oštećenja.

Upravo je baterija glavni uzrok male komercijalne uporebe električnih automobila. Puno je utjecaja kao što je okolišna temperatura, način i uvjeti vožnje, grijanje vozila i slične pojave koje utječu na ubrzano trošenje energije baterije u električnom vozilu.

Mana baterija kod električnih automobila je i njihova masa koja može iznositi 200 kg ili čak i više što može iznositi i jednu četvrtinu mase automobila. Razvijanjem novih tehnologija i materijala se svakodnevno razvijaju i nove baterije te se smatra da će se u skoroj budućnosti razviti baterije koje zadovoljavaju sve uvjete korištenja.

**BMS** (eng. *battery management system*) – sustav upravljanja baterijom koji je postavljen na svaku ćeliju baterije te nadzire temperaturu i prati status punjenja svake ćelije zasebno. U interakciji je sa stanicom za punjenje preko koje se definira struja punjenja te je ujedno i sigurnosni čimbenik tijekom ciklusa punjenja i pražnjenja baterije [21]. Nadzire mnogo faktora koji utječu na vijek i funkciju baterije, a pomoću njega se i korisniku prikazuju podaci o kapacitetu i napanjenosti baterije.

## 5. PRIMJENA AHP METODE

Kao primjer primjene AHP metode prikazat će se proces izbora električnog automobila za uslugu Car sharing. Važnost tog izbora je u tome što je to veliki financijski i tehnički projekt koji zahtjeva detaljnu razradu svakog elementa.

### 5.1. Kriteriji

Uspješnost implementacije usluge Car sharing ovisi o mnogo čimbenika. Jedan od najvažnijih, a ujedno i tehnički čimbenik je vrsta automobila koji će biti u ponudi usluge. Nabava automobila je i najskuplji dio projekta pa ispravan izbor utječe na isplativost i efektivnost usluge. Kako je Car sharing usluga koja potiče suživot korisnika i održivi razvoj gradova, električni automobil se nameće kao logičan izbor. Tržište u zadnje vrijeme nudi mnogo različitih klasa i vrsta električnih automobila pa dolazi do pitanja koji je električni automobil najbolji za uslugu Car Sharing. Važnost odabira vrste električnog automobila nije samo u isplativosti projekta nego je u cilju i korisnicima ponuditi kvalitetnu, sigurnu i udobnu varijantu koja je prihvatljivija od posjedovanja osobnog automobila. Zbog načina kako usluga funkcionira nekoliko je najvažnijih kriterija koji određuju izbor.

#### 5.1.1. Domet

Domet je jedan od najvažnijih kriterija na kojima se temelji izbor električnog automobila. Zbog ograničenosti kapaciteta baterije domet još uvijek predstavlja najveću prepreku za masovno korištenje električnih automobila. Iako se novi materijali i tehnologije svakodnevno razvijaju, električni automobili još uvijek nemaju neovisnost kao konvencionalni automobili jer baterija im ne dopušta domen veći od u prosjeku 150 km. Domet ovisi o uvjetima vožnje, vremenskim prilikama, korištenju dodatne opreme u automobilu te mnogim drugim čimbenicima o kojima korisnici možda neće voditi pretjeranu brigu pa je domet svakako najvažniji kriteriji prilikom izbora električnog automobila. Jedan od nedostataka električnog vozila je još uvijek neovisan sustav za hlađenje i grijanje kabine vozila koji koristi energiju iz baterije i motora kako bi regulirao temperaturu te tako smanjuje ionako ograničen domet. Iako moderne punionice omogućavaju brzo punjenje koje u razdoblju od pola sata nadomještaju 80% kapaciteta baterije za dinamičnu uslugu kao što je Car Sharing važno je da automobil

bude što više vremena dostupan sa što većim dometom. Prosječni električni automobil ima domet od 150 km, ali razvojem baterija u skoroj budućnosti domet bi se trebao uveliko povećati.

### **5.1.2. Baterija**

Drugi važan kriteriji koji utječe na izbor električnog automobila je vrsta i kapacitet baterije. Baterija kao izvor energije je jedan od osnovnih dijelova električnog automobila te time utječe i na mogućnost eksploatacije i učinkovitost vozila. Najčešća baterija koja se koristi u električnim vozilima je na bazi litija, ali se zbog ograničene dostupnosti litija i ograničenih karakteristika takve baterije istražuje u drugim smjerovima kako bi se pronašao materijal i tehnologija koja bi uspješno zamijenila litiji-ionske baterije. Vrsta baterije je bitna jer različite baterije imaju različite karakteristike pa je tako litij-polimerska baterija oblikom prilagodljivija od litij-ionske. Najveća prednost litij-željzno fosfatne baterije je sigurnost jer je prilikom mehaničkog oštećenja nezapaljiva za razliku od ostalih baterija koje se koriste u električnim i hibridnim vozilima. Druga karakteristika baterije koja bitno utječe na izbor električnog automobila je kapacitet baterije. Kapacitet baterije je ona količina energije koja može biti pohranjena punjenjem i iskorištena tijekom eksploatacije vozila. Ograničenje koje utječe na relativno male kapacitete, a time i domet električnih vozila je velika masa i volumen baterija. Moguće je napraviti bateriju velikog kapaciteta, ali za sada takva baterija bi bila jako velike mase i zauzimala bi jako puno prostora pa samim time i karakteristike vožnje ne bi bile kao što je svaki vozač do sada navikao. Povećanjem mase bi se povisila potrošnja energije potrebna za pogon tako da je trenutno stanje na tržištu najefikasnije što tehnologija trenutno može ponuditi. Kod izbora električnog automobila poželjno je da baterija bude što većeg kapaciteta kako bi se time povećao i domet.

### **5.1.3. Snaga motora**

Snaga motora kod električnih vozila ima jednaku ulogu kao i snaga motora kod konvencionalnih automobila. Što je veća snaga koju motor može isporučiti to je veća maksimalna brzina koju automobil može postići. Električni automobili imaju elektromotore male nazivne snage zbog toga što se prikazuje snaga koju motor može trajno isporučiti, a trenutna snaga može biti i deset puta veća od nazivne. Snaga elektromotora nije najbitniji kriteriji prilikom izbora električnog automobila za uslugu Car Sharing zbog specifičnosti

eksploatacije. Usluga je predviđena za gradsko područje na kojem se ni ne može razviti velika brzina pa je tako i automobil manje snage pogodan za takvo korištenje. Na većini gradskih prometnica ograničenje brzine ne prelazi 80 km/h dok je na gradskoj zaobilaznici ograničenje brzine 130 km/h što svaki električni automobil može postići, ali porastom brzine raste i potrošnja energije. Iako snaga motora ne igra bitnu ulogu prilikom odabira gradskog automobila, poželjno je da snaga bude što veća kako bi i vozne karakteristike bile bolje.

#### 5.1.4. Okretni moment

Okretni moment je povezan sa snagom motora. Što je veći okretni moment to je veća snaga koju će motor isporučiti pri manjem broju okretaja što prikazuje i formula:

$$P = M \times \frac{n}{9414.21}$$

gdje je:

P – snaga [W]

M – okretni moment [Nm]

n – broj okretaja motora [1/min]

Okretni moment je zadužen za pokretanje automobila pa se time i nameće kao važan kriteriji prilikom odabira automobila koji će se koristiti na gradskim prometnicama.

#### 5.1.5. Potrošnja

Potrošnja energije je jedan od najvažnijih kriterija pri izboru električnih automobila za uslugu Car Sharing. Usluga koja se temelji na tome da korisnici u svakom trenutku na raspolaganju imaju automobil zahtjeva da automobil bude spreman za vožnju, a to se može ostvariti samo ako ima dovoljno energije pohranjeno u spremniku. Iako bi se dalo zaključiti da je kapacitet baterije glavna karakteristika koja omogućava stanje vozila spremno za dugo korištenje, potrošnja je isto tako karakteristika koja utječe na dostupnost vozila u što dužem periodu. Zbog sličnosti kapaciteta baterija gotovo svih vozila glavnu razliku u čuvanju i iskorištavanju energije čini potrošnja. Prilikom računanja vektora prioriteta za alternative potrebno je maksimizirati vektor prioriteta zbog toga što je za uslugu bolje da potrošnja bude što manja. Kasnije u radu će se prikazati taj postupak.

#### **5.1.6. Jamstvo**

Jamstvo je kriterij koji daje sigurnost da će automobili raditi na način koji se očekuje i da u slučaju nekih grešaka slijedi brz i učinkovit popravak. Za uslugu koja uključuje puno automobila važno je da svi automobili budu u raspoloživom stanju što više vremena kako bi cijeli projekt bio isplativ i učinkovit. Svaki proizvođač daje jamstvo na cijele automobile ili pojedine dijelove što kupcima daje sigurnost. Kako električni automobili još uvijek nisu u masovnoj eksploataciji tako još uvijek nema ni dovoljno servisa za održavanje pa je nužno da za uslugu kao što je car sharing postoji jamstvo proizvođača i odgovarajući servis koji može riješiti sve probleme koji se pojave prilikom korištenja. Dužina i opseg jamstva utječe i na cijenu automobila, ali uzimajući u obzir sve troškove zastoja i popravka, jamstvo je jako važan kriterij. Kod električnih automobila najčešće se razlikuju dva jamstva. Postoji oblik jamstva na karoseriju, unutrašnjost, motor, elektroinstalacije i ostale dijelove koji su jednaki kod električnog i konvencionalnog automobila te posebno jamstvo na bateriju. Baterija je jedan od skupljih i važnijih dijelova električnih automobila što se očituje i posebnim jamstvom.

#### **5.1.7. Troškovi**

Car Sharing je ujedno i tehnički i ekonomski projekt koji ovisi o nizu čimbenika koji će prikazati uspješnost projekta. Troškovi cijelog projekta uključuju nekoliko segmenata kao što je nabavna cijena automobila, nabava, instalacija i održavanje softvera, održavanje automobila, osiguranje i registracija vozila te radna snaga. Svi kriteriji osim nabavne cijene automobila su jednaki za sve tipove automobila ili se razlikuju jako malo pa je tako nabavna cijena vozila kriteriji koji najviše određuje troškove cijelog projekta. Prilikom korištenja AHP metode za odabir električnog automobila uzet će se u obzir samo nabavna cijena koja i jedina čini razliku između troškova za različite tipove automobila. Kod računanja prioriteta za alternative potrebno je provesti normalizaciju troškova te ih staviti u odnos s benefitima svake alternative.

U tablici 5.1. prikazani su kriteriji i alternative koje ulaze u proces odabira električnog automobila za uslugu Car Sharing. Odabrane alternative su svi električni automobili koji se nalaze na tržištu Republike Hrvatske. Na europskom tržištu se nalazi još nekoliko tipova električnih automobila koji bi mogli zadovoljiti kriterije usluge Car Sharing, ali zbog strategije pojedinih proizvođača ti se automobili ne nalaze na hrvatskom tržištu pa zbog toga nije razvijena ni mreža servisa za te tipove električnih automobila. Ako bi Car Sharing postao usluga raširena po cijeloj Hrvatskoj ili čak regiji, Hrvatska ima dobar položaj da aktivno sudjeluje u proizvodnji i distribuciji dijelova i opreme za električne automobile i tehničku podršku usluge.






Kriterij/Automobil	Domet [km]	Okretni moment [Nm]	Baterija [kWh]	Snaga [kW]	Cijena [kn]	Jamstvo [god]	Potrošnja [ $\frac{kWh}{100km}$ ]
VW Up	160	210	18,7	60	195.000	4/8*	11,7
VW e-Golf VII	170	270	24,2	85	295.000	4/8*	12,7
KIA Soul EV	200	285	27	90	270.000	7/7*	14,7
Citroen C-Zero	150	180	14,5	49	230.000	5/5*	10,7
Mitsubishi I miEV	160	196	16	49	205.000	3/7*	12,5

\*jamstvo na bateriju

**Tablica 5.1. Prikaz alternativa i kriterija**

U tablici su prikazani prikupljeni podaci za pojedine automobile koji su ujedno i ulazni podaci za Expert Choice. Označeni podaci predstavljaju najbolju karakteristiku određenog kriterija od ponuđenih alternativa. Bez korištenja AHP metode moglo bi se zaključiti da KIA Soul EV zadovoljava najviše kriterija te da je zbog toga i najbolji izbor, ali AHP metoda će zapravo prikazati odnos važnosti pojedinog kriterija i konačni rezultat koji može biti različit od početne pretpostavke. Postavljanje odnosa između pojedinih kriterija je subjektivan proces temeljen na iskustvu i prethodno stečenom znanju što različitim rangiranjem važnosti kriterija dovodi do drugačijih rezultati. Pomoć pri donošenju odluke donijet će se pomoću softverske podrške. Expert Choice je alat koji skraćuje put donošenja odluke te na jednostavan način pomaže donositelju odluke kod kompleksnih problem.

U tablici 5.2. su prikazani tipovi električnih automobila za uslugu Car Sharing. Svi automobili su pogodni za gradski promet s mogućnošću prijevoza do 5 putnika.

AUTOMOBIL	SLIKA
<b>Volkswagen e-Up</b>	
<b>Volkswagen e-Golf VII</b>	
<b>Citroen C-Zero</b>	
<b>Mitsubishi I miEV</b>	
<b>KIA Soul EV</b>	

**Tablica 5.2. Prikaz električnih automobila**



---

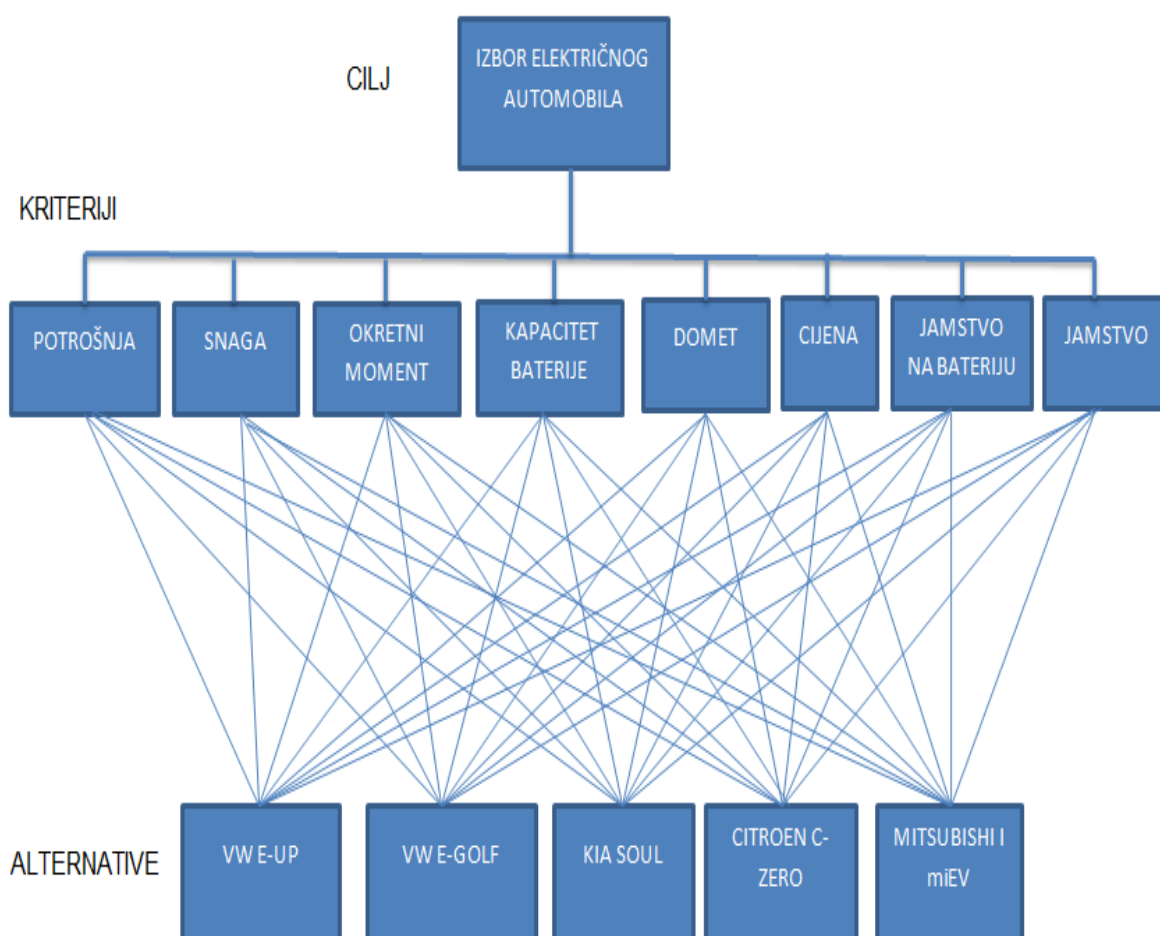
## 5.2. Softver Expert Choice

Expert Choice je softverska podrška za rješavanje problema višekriterijskog odlučivanja. Razvijen je na temelju potrebe da se rješavanje problema pomoću AHP metode ubrza i digitalizira. Razvili su ga Thomas Saaty i dr. Ernest Forman u ranim 1980-im. Koristi se u raznim granama industrije kao pomoć pri rješavanju problema donošenja odluke na temelju više različitih, kvantitativnih i kvalitativnih kriterija pa se tako primjenjuje i u granama društva kao što su proizvodnja, marketing, vojno područje, upravljanjem projektima i sličnim područjima gdje je potrebno donijeti kompleksne odluke. Program omogućuje formiranje problema i njegovo strukturiranje bez ograničenja na kompleksnost strukture. Posjeduje opcije koje omogućavaju razne analize ili promjene ulaznih podataka kojima se mogu simulirati razne situacije. [22]

Pomoću programa kao što je Expert Choice donositelj odluke lakše sagledava cijeli problem i može objektivnije donijeti konačnu odluku. Takav alat daje optimalno rješenje prema zadanim kriterijima te se na taj način pospješuje cijeli projekt. Expert Choice je koristan alat koji na brz i učinkovit način pomaže pri donošenju odluke kod nekog problema. Iako program daje najobjektivnije rješenje prema zadanim kriterijima korisnik donosi konačnu odluku te je na njemu najveća odgovornost. Važno je naglasiti subjektivnost korisnika u procjeni važnosti kriterija te procjeni kvalitativnih kriterija što bitno utječe i na rezultat procesa odabira putem AHP metode podržanom softverom Expert Choice.

## 6. IZBOR ELEKTRIČNOG AUTOMOBILA

Nakon što su definirani cilj odabira, kriteriji na temelju kojih se donosi odluka te alternative, potrebno je koristeći AHP metodu donijeti odluku izbora električnog automobila za uslugu Car Sharing. Na slici 6.1. je prikazan hijerarhijski model problema u tri razine.



**Slika 6.1. Prikaz hijerarhijskog modela**

Proces provedbe AHP metode se može provesti računajući pomoću matrica ili pomoću softverske podrške kao što je program Expert Choice.

Prije samog analitičkog hijerarhijskog procesa potrebno je ponderirati kriterije po važnosti. Poredak je napravljen prema iskustvu i pretpostavci kako funkcionira usluga Car Sharing i

koji su kriteriji od najvećeg značaja. Ponderiranje kriterija je jedan od najvažnijih koraka, a ujedno i izrazito subjektivan jer se na taj način bitno utječe na rezultat.

Poredak kriterija:

1. Domet
2. Kapacitet baterije
3. Potrošnja
4. Jamstvo
5. Cijena
6. Okretni moment
7. Snaga

Kao što je već objašnjeno kod razrade pojedinog kriterija, domet je najvažniji kriteriji za uslugu car sharing. Potrebno je da automobili imaju što veću autonomiju, tj. da mogu prijeći što veće udaljenosti bez potrebe nadopunjavanja spremnika. Specifičnost usluge je takva da korisnici u svakom trenutku imaju na raspolaganju automobil koji može ispuniti njihove zahtjeve.

Kapacitet baterije je zajedno s potrošnjom energije kriteriji koji u najvećoj mjeri određuje domet električnog automobila. Odabrane alternative imaju različite kapacitete baterija što je možda i najveća razlika jer potrošnje su im slične. Razvojem baterija trebao bi se povećati i kapacitet što bi rezultiralo i većim dometom.

Jamstvo je kriteriji koji osigurava da cijeli projekt ide u željenom smjeru. U slučaju otkazivanja pojedinih dijelova proizvođač će u što kraćem roku riješiti problem kako bi usluga bila dostupna bez ikakvih gubitaka. Jamstvo je i vrsta financijske sigurnosti jer pokriva nepredviđene troškove u slučaju kvarova.


Car Sharing je i ekonomski projekt od kojeg se očekuje zarada pa su troškovi implementacije usluge jedan od bitnijih kriterija prilikom odabira električnog automobila. Cijena automobila i njezin utjecaj kao kriteriji će se prikazati pri konačnom izboru gdje će se staviti u odnos s benefitima svake alternative.

Okretni moment i snaga su kriteriji koji su povezani, ali ipak postoji razlika. Kod električnih automobila namijenjenih za gradsku vožnju, okretni moment je važnija karakteristika jer predstavlja startnost automobila što je za gradsku vožnju bitno. Snaga motora omogućava maksimalnu brzinu automobila što nije najbitniji kriteriji za ovakvu uslugu jer na gradskim prometnicama postoje ograničenja koja su ispod maksimalnih mogućnosti električnih automobila odabranih među alternative.

Nakon ponderiranja kriterija moguće je provesti odabir električnog automobila za uslugu Car Sharing AHP metodom pomoću softverske podrške Expert Choice.

### 6.1. Rezultati AHP metode u Expert Choiceu

Pomoću Expert Choicea dobiveni su rezultati koji pomažu pri donošenju odluke. Kao najbolja alternativa izabran je električni automobil KIA Soul EV kao i prema pretpostavci. Slika 6.2. prikazuje rezultat u programu Expert Choice.



Slika 6.2. Prikaz rezultata odabira


Nakon definiranja kriterija potrebno ih je i ponderirati u programu. Iako je unaprijed određen poredak između kriterija, najteži korak je definirati odnos njihove važnosti. Taj postupak je subjektivan i određuje konačnu odluku. Poredak kriterija je prikazan na slici 6.3.

Priorities with respect to:  
Goal: Odabir elektricnog automobila



Slika 6.3. Poredak kriterija prema važnosti

Na slici 6.4. je prikazan postupak postavljanja brojčanog odnosa prema Saatyjevoj skali za sve kriterije te je time dobivena raspodjela kriterija prema važnosti. Na slici je prikazan i indeks konzistentnosti koji je *manji od deset posto* što dokazuje da je postupak konzistentan.



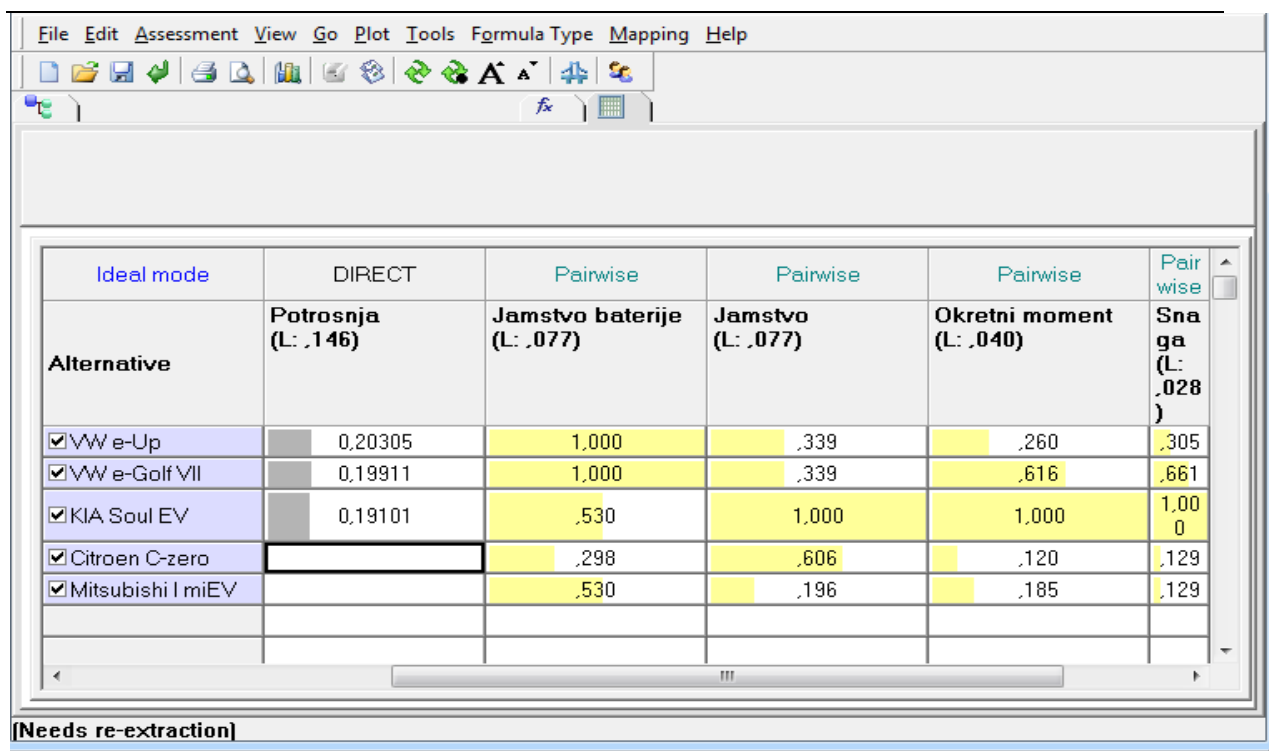
Slika 6.4. Prikaz odnosa kriterija

Za kriteriji potrošnje je bilo potrebno minimizirati vrijednost kriterija. Postupak je prikazan na slici 6.5.

	Potrosnja [kWh/100km]	
VW e-Up	11.7	$1 - (11,7/62,3) = 0,8122/4 = 0,20305$
VW e-Golf VII	12.7	$1 - (12,7/62,3) = 0,7962/4 = 0,19911$
KIA Soul EV	14.7	$1 - (14,7/62,3) = 0,7640/4 = 0,19101$
Citroen C-Zero	10.7	$1 - (10,7/62,3) = 0,8283/4 = 0,20706$
Mitsubishi I miEV	12.5	$1 - (12,5/62,3) = 0,7994/4 = 0,19984$
	$\Sigma 62,3$	

Slika 6.5. Prikaz minimiziranja vrijednosti kriterija

Kako kod kriterija potrošnje prednost ima alternativa koja ima manju vrijednost, alternative se ne uspoređuju u parovima prema Saaty skali nego se minimizirana vrijednost kriterija izravno unosi u program što je prikazano na slici 6.6.



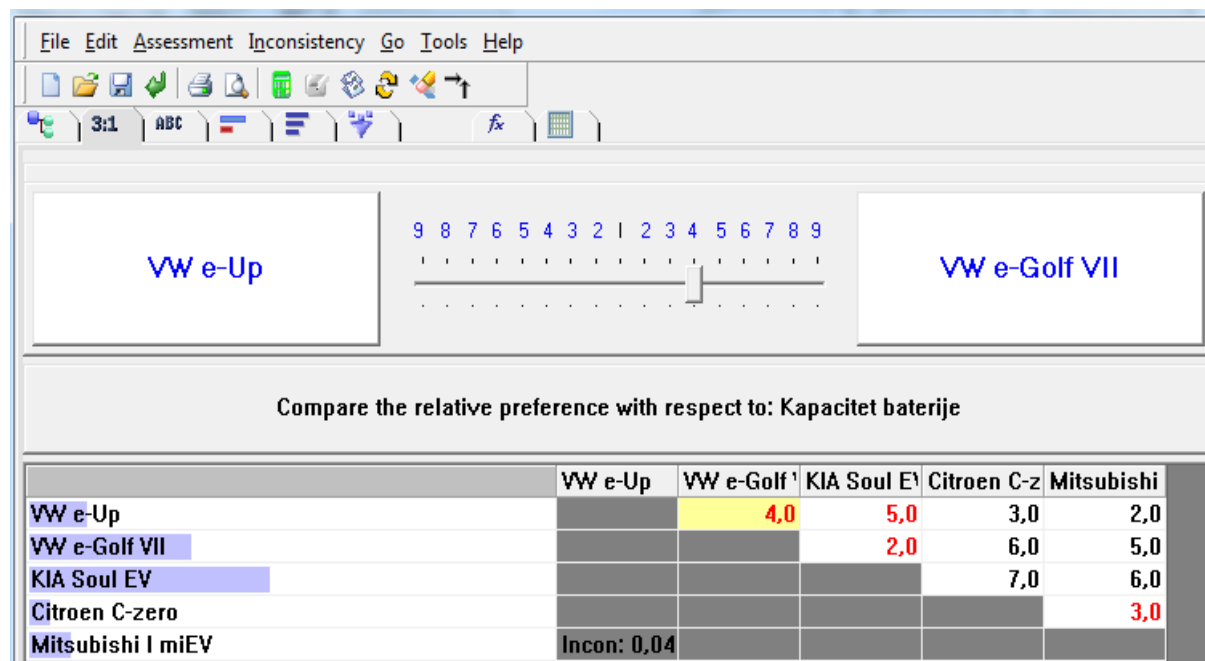
The screenshot shows a software window with a menu bar (File, Edit, Assessment, View, Go, Plot, Tools, Formula Type, Mapping, Help) and a toolbar. Below is a table with the following data:

Ideal mode	DIRECT	Pairwise	Pairwise	Pairwise	Pairwise
Alternative	Potrosnja (L: ,146)	Jamstvo baterije (L: ,077)	Jamstvo (L: ,077)	Okretni moment (L: ,040)	Snaga (L: ,028)
<input checked="" type="checkbox"/> VW e-Up	0,20305	1,000	,339	,260	,305
<input checked="" type="checkbox"/> VW e-Golf VII	0,19911	1,000	,339	,616	,661
<input checked="" type="checkbox"/> KIA Soul EV	0,19101	,530	1,000	1,000	1,000
<input checked="" type="checkbox"/> Citroen C-zero		,298	,606	,120	,129
<input checked="" type="checkbox"/> Mitsubishi I miEV		,530	,196	,185	,129

At the bottom of the window, a status bar displays the text: [Needs re-extraction]

Slika 6.6. Unošenje minimizirane vrijednosti kriterija

Nakon što su uneseni svi kriteriji i ponderirani prema Saatyjevoj skali, potrebno je rangirati i alternative prema pojedinim kriterijima. Prema prikupljenim podacima o svakoj alternativu donosi se zaključak o odnosu između dvije alternative i to se definira prema Saatyjevoj skali. Postupak je prikazan na slici 6.7.




The screenshot shows a pairwise comparison window. At the top, there are two boxes labeled 'VW e-Up' and 'VW e-Golf VII'. Between them is a scale from 1 to 9. Below the scale is a slider. The text 'Compare the relative preference with respect to: Kapacitet baterije' is displayed. At the bottom is a table with the following data:

	VW e-Up	VW e-Golf VII	KIA Soul EV	Citroen C-zero	Mitsubishi
VW e-Up		4,0	5,0	3,0	2,0
VW e-Golf VII			2,0	6,0	5,0
KIA Soul EV				7,0	6,0
Citroen C-zero					3,0
Mitsubishi I miEV	Incon: 0,04				


Slika 6.7. Prikaz postupka rangiranja alternativa

Kada su svi kriteriji i alternative ocijenjene i poredane prema važnosti, može se provesti analiza. Kao što je prikazano na slici 6.8, najbolja alternativa je KIA Soul EV koja prema zadanim kriterijima najbolje odgovara za uslugu kao što je Car Sharing.



Slika 6.8. Analiza dobivenih rezultata

Prema grafičkoj analizi jasno je vidljivo da je najbolja alternativa bolja prema kriterijima dometa, kapaciteta baterije, jamstva, okretnog momenta i snage. U preostala dva kriterija, potrošnja i jamstvo baterije, bolje su alternative VW e-Up i VW e-Golf VII. Kada bi se odnos kriterija promijenio dobili bi se i drugačiji rezultati što prikazuje slika 6.9.



Slika 6.9. Analiza s promijenjenim kriterijima

Promijenom važnosti kriterija dobiveni su rezultati koji se bitno razlikuju od prvih rezultata. Ako bi najbitniji kriteriji bili jamstvo i kapacitet baterije te potrošnja, najbolja alternativa bi bila VW e-Golf VII. Ovdje je dokazana veza ponderiranja kriterija i konačnog rezultata. U takvim slučajevima važnu ulogu ima donositelj odluke koji najbolje zna koji su kriteriji najvažniji te time ima i najveću odgovornost. Ovdje je prikazano kako subjektivnost donositelja odluke pri rangiranju kriterija i njegovo poznavanje razmatranog područja izravno utječe na rezultat odluke što je ujedno i najveća mana AHP metode.

## 6.2. Konačni odabir

Za konačni odabir potrebno je provesti benefit/troškovi analizu. Benefiti su vrijednosti iz vektora cilja dok su troškovi normalizirane vrijednosti cijene automobila. Postupak je prikazan u tablici 6.1.

	Cijena [kn]	Normalizirana cijena - T	Benefit - B	B/T
VW e-Up	195.000	$195.000/1.195.000 = 0,16318$	0,155	0,94987
VW e-Golf VII	295.000	$295.000/1.195.000 = 0,24686$	0,239	0,96816
KIA Soul EV	270.000	$270.000/1.195.000 = 0,22594$	0,370	1,6376
Citroen C-Zero	230.000	$230.000/1.195.000 = 0,19247$	0,110	0,5715
Mitsubishi I miEV	205.000	$205.000/1.195.000 = 0,17155$	0,126	0,7345
Ukupno	1.195.000			

**Tablica 6.1. Proračun B/T**

Iz tablice je vidljivo da je alternativa izabrana pomoću Expert Choicea i nakon benefit/trošak analize najbolji izbor. Utjecaj troškova je jako bitan jer se pomoću AHP metode može dobiti preskupa alternativa s velikim brojem benefita što nikako nije ono što se traži. Kod ove analize nisu ubrojeni troškovi održavanja automobila i cijelog sustava te dodatni troškovi vezani uz automobile zbog pretpostavke da su ti troškovi jednaki za sve alternative.

Nakon svih analiza prikazano je da je KIA Soul EV najbolja alternativa koja se nalazi na tržištu za uslugu Car Sharing. To je električni automobil koji će zadovoljiti potrebe svih korisnika, a ujedno će biti isplativ i za davatelja usluge.



## 7. AUTOMOBILSKA INDUSTRIJA U REPUBLICI HRVATSKOJ

Iako u Republici Hrvatskoj ne postoji automobilska industrija u punom smislu, na svjetskom tržištu postoji veliki broj proizvođača automobila te tako postoji i potreba za proizvodnju pojedinih dijelova. Postoje mnoge tvrtke u RH koje proizvodeći pojedine dijelove čine bitan dio proizvodnje automobila. Udruživanjem u klastere, takve tvrtke su dobile mogućnost probijanja na svjetsko tržište te se iznova otvara prilika za nove poslovne prilike. Udruge proizvođača dijelova i ostalog pribora za automobilsku industriju omogućavaju suradnju pojedinih tvrtki te jačanje pozicije na tržištu. U Hrvatskoj postoji nekoliko klastera koji omogućavaju tvrtkama bolju suradnju i kontinuirano unaprijeđenje kvalitete proizvoda, a time i bolji poslovni uspjeh. Sve više tvrtki uočava prednosti udruživanja u klaster te koristi priliku zajedničkog djelovanja.

Implementacijom usluge Car Sharing u više gradova RH, ili čak diljem regije, otvorila bi se prilika za jačanjem gospodarstva u obliku razvijanja autoindustrije. Iako već sada postoje tvrtke koje aktivno sudjeluju u proizvodnji automobila, pojačana implementacija usluge Car Sharing dovela bi takve tvrtke u još bolju poziciju na svjetskom tržištu. Kada bi država imala ulogu u pružanju same usluge, stvorila bi se pozicija u kojoj bi se kupovinom velikog broja automobila stvorili uvjeti za razvijanje određenih grana autoindustrije. Električni automobili još uvijek nemaju raširenu mrežu specijaliziranih servisa što stvara priliku za sve one koji žele biti dio autoindustrije.

Car Sharing je veliki financijski projekt koji stvara mogućnost razvijanja mnogih grana industrije. Autoindustrija je grana industrije koja zahtjeva veliku preciznost i kvalitetu, te svaki proizvođač koji ispunjava te uvjete ostvaruje i veliki prihod. Električni automobili su još uvijek relativno nepoznanica u svijetu automobila te se tu otvara prilika za razvijanje novih tehnologija i komponenti. Udruživanjem znanosti i industrije može se stvoriti podloga za razvijanje potpuno novih grana industrije koje sada nisu zastupljene, a mogu imati značajnu ulogu u gospodarskom rastu. Kako je i prije navedeno, spremnik energije u električnom automobilu je najveća zapreka masovnog korištenja takvog automobila i upravo je razvijanje te komponente najveća prilika za uzimanje vodećeg mjesta na svjetskom tržištu.

U tablici 7.1. su prikazani primjeri hrvatskih tvrtki koje značajno sudjeluju u svjetskoj automobilskoj industriji. Automobilska industrija može činiti glavnu granu gospodarstva, te je

i zbog toga važna implementacija usluga kao što je Car Sharing na široko područje jer se time jača i pozicija lokalne autoindustrije na svjetskom tržištu.

Proizvođači	Opis djelatnosti	Partneri
AD Plastik d.d.	Plastični dijelovi	Renault, Dacia, VW, BMW, Opel, Peugeot...
Boxmark Leather d.o.o.	Kožne komponente	Mercedes-Benz, BMW, Audi, Opel, Porsche, Ford, VW...
Cimos – P.P.C. Buzet	Lijevanje Al - legura	Audi, BMW, Opel, VW...
Feroimpex automobilska tehnika d.o.o.	Kučišta i prsteni za ležajeve	-
HSTec d.d.	Projektiranje i proizvodnja preciznih visokobrzinskih elektromotornih vretena	Njemačka, Austrija, Švicarska...
Kostel Promet d.o.o.	Nasloni za ruku i glavu	VW, Škoda, Toyota, Volvo...
Kaplast d.d.	Plastični proizvodi tehnologijom injekcijskog prešanja	Renault
LTH Metalni lijev d.o.o.	Lijevanje i obrada aluminijskih blokova	Audi, Bosch, BMW...
Končar – MES d.d.	Elektromotori	-
DOK-ING d.o.o.	Robotizirana vozila, električni automobil	-
Lipik Glas d.o.o.	Autostakla	Bentley, Ferrari...
Munja d.d.	Olovni akumulatori	-
Rimac automobili d.o.o.	Električni automobil	-

**Tablica 7.1. Primjer tvrki iz RH koje sudjeluju u autoindustriji**

## 8. ZAKLJUČAK

Implementacija usluge kao što je Car Sharing zahtjeva detaljnu analizu i pripremu svakog segmenta projekta kako bi se u konačnici zadovoljili svi ciljevi. Odabir automobila je najvažniji korak pri pokretanju takve usluge jer zahtjeva i najveće investicijske troškove. Analitički hijerarhijski proces je pomoć pri rješavanju kompleksnih problema te na brz i jednostavan način donosi pomoć pri odluci uzimajući u obzir mnoge parametre. Kod rješavanja problema kao što je izbor električnog automobila za specifičnu uslugu Car Sharing-a, važno je uzeti u obzir što više kriterija koji utječu na uspješnost projekta.

Analizirajući kriterije i prikupljajući podatke stvara se podloga za provedbu AHP metode. Car Sharing je usluga koja zahtjeva ekološki prihvatljive, ekonomične, udobne i sigurne automobile, te je potrebno izabrati automobil koji zadovoljava sve te kriterije. Električni automobil je jedan od predvodnika koncepta pametnog grada pa je tako i logičan izbor pri izboru vrste vozila. Nažalost, na dostupnom tržištu ne postoji velik izbor električnih automobila što predstavlja ograničenje pri realizaciji projekta.

AHP metoda je znanstvena podloga pri rješavanju problema izbora između više alternativa što je prikazano i na primjeru izbora električnog automobila. Definiranje odnosa između kriterija je najvažniji korak AHP metode jer promijenom tog odnosa mijenja se i rezultat. Iako je AHP metoda dobar način za donošenje odluka, treba biti svjestan ljudskog utjecaja na cijeli proces. Iskustvo donositelja odluke i znanje o problemu koji se rješava su odlučujući faktori pri donošenju odluke pomoću AHP metode te iako metoda ima matematičku podlogu, konačnu odluku donosi čovjek koji s time ima i najveću odgovornost.

## LITERATURA

- [1] Vlah, S.: Magistarski rad: Modeli višekriterijskog odlučivanja i heuristike za njihovo rješavanje, Ekonomski fakultet Zagreb, Zagreb, 2008.,
- [2] Kovačić, B.: Magistarski rad: Višekriterijsko odlučivanje u prometu, Fakultet prometnih znanosti, Zagreb, 2004.,
- [3] Decision Support Tools. <http://www.ifm.eng.cam.ac.uk/research/dstools/#information>,
- [4] Decision Support Systems Resources. <http://dssresources.com/>,
- [5] AHP method. [https://en.wikipedia.org/wiki/Analytic\\_hierarchy\\_process](https://en.wikipedia.org/wiki/Analytic_hierarchy_process),
- [6] Begićević, N.: Doktorska dizertacija: Višekriterijalni modeli odlučivanja u strateškom planiraju uvođenja e-učenja. FOI. Varaždin, 2008.,
- [7] Lisjak, Dragutin. Održavanje. Održavanje. Fakultet strojarstva i brodogradnje. Zagreb, studeni 2015.,
- [8] Holjevac, N., Kuzle, I., Zidar, M., Modrovčić, M.: Razvoj modela analitičkog hijerarhijskog procesa i njegovo korištenje pri donošenju odluke o prelasku na 20 KV pogonski napon. Trogir, svibanj 2014.,
- [9] Damjanović, D. *Primena AHP metode na selekciju i evaluaciju dobavljača*. Univerzitet Singidunum, Beograd, 2013.,  
<http://www.singipedia.singidunum.ac.rs/content/3371-Primena-AHP-metode-na-selekciju-i-evaluaciju-dobavlja%C4%8Da>,
- [10] Car Sharing. <http://carsharing.org/what-is-car-sharing/>,
- [11] Car Sharing - primjer. <https://www.car2go.com/en/berlin/how-does-car2go-work/>,
- [12] Zipcar. <http://www.zipcar.com/is-it#greenbenefits>,
- [13] Spin City. <http://www.vecernji.hr/minuta-voznje-autom-kostat-ce-262-kune-1026246>,
- [14] Citroen Savska. <http://hr.n1info.com/a54494/Vijesti/Hrvati-u-automobilu-provode-56-minuta-dnevno.html>,
- [15] Električni automobil. [https://hr.wikipedia.org/wiki/Elektri%C4%8Dni\\_automobil](https://hr.wikipedia.org/wiki/Elektri%C4%8Dni_automobil),
- [16] Električni automobil. <http://elen.hep.hr/EL-vozilo-definicija.aspx>,
- [17] Električni automobil. <http://www.e-auto.guru/pitanja-dogovori/>,
- [18] Zavod za visoki napon i energetiku: Izvješće o punionicama automobila, Fakultet elektrotehnike i računarstva, Zagreb, rujan 2015.,

- 
- [19] Punionice. <http://puni.hr/chargingSpotsMgr.php?SGLSESSID=8lektc8uufu60j8np6t53636l0>,
- [20] Baterije. <http://electricvehicles.caa.ca/types-of-electric-vehicles/battery-types/>,
- [21] BMS. <http://whatis.techtarget.com/definition/battery-management-system-BMS>,
- [22] Expert Choice. <http://expertchoice.com/about-us/what-we-offer/>,

## **PRILOZI**

- I. CD-R disc
- II. AHP metoda

## **PRILOG II: AHP metoda – primjer i opis postupka**

U Prilogu II. bit će opisan matematički postupak AHP metode baziran na jednostavnom primjeru. Na isti način radi program Expert Choice.

Analitički hijerarhijski proces (AHP) rješava se u četiri faze:

0. Faza – strukturiranje problema – odredi se cilj za koji se odrede kriteriji te alternative.
1. Faza – određivanje najznačajnijeg kriterija – faza u kojoj se kriteriji uspoređuju u parovima prema međusobnim prioritetima.
2. Faza – određivanje najznačajnije alternative – faza u kojoj se alternative uspoređuju u parovima prema međusobnim prioritetima za svaki postavljeni kriterij.
3. Faza – određivanje konačnog rješenja (cilja) – na temelju prethodna dva koraka određuje se najbolje rješenje.


Kao primjer funkcioniranja i provedbe matematičkog modela AHP metode koristit će se slučaj odabira televizora na temelju tri kriterija:

- veličina ekrana
- učestalost kvara
- dizajn

Kao alternative odabrat će se četiri različita proizvođača:

- *Panasonic*
- *Samsung*
- *Sony*
- *LG*

Struktura problema prikazana je na slici 1.



**Slika 10. Struktura problema**

### **1.1. 1. Faza – određivanje najznačajnijeg kriterija**

Kriteriji se međusobno vrednuju i uspoređuju u parovima pomoću Saatyjeve skale. Saatyjeva skala sastoji se od brojeva od 1 do 9, gdje 1 označava podjednaku važnost, a 9 ekstremnu važnost (prioritet) jednog kriterija nasuprot drugom.

Međusobne se usporedbe objedinjuju u matrici odlučivanja (Slika 2.) po sljedećem principu: ako je ocjena na lijevoj strani, u redak se unosi stvarna vrijednost, a ako je ocjena na desnoj strani, unosi se recipročna vrijednost.



	Veličina ekrana	Učestalost kvara	Dizajn
Veličina ekrana	1.00	0.33	2.00
Učestalost kvara	3.00	1.00	4.00
Dizajn	0.50	0.25	1.00

Slika 11. Matrica odlučivanja

Iz Slike 2. vidljivo je kako je kriterij učestalosti kvarova četiri puta važniji od kriterija dizajna, odnosno da je kriterij veličine ekrana tri puta manje važniji od kriterija učestalosti kvarova. Po dijagonali matrice nalaze se jedinice jer se kriteriji ne uspoređuju sami sa sobom, odnosno, podrazumijeva se da su one međusobno jednake važnosti pa im je zato dodijeljena jedinica. Matrica kriterija (odlučivanja) se množi sama sa sobom (Slika 3.).

	Veličina ekrana	Učestalost kvara	Dizajn
Veličina ekrana	1.00	0.33	2.00
Učestalost kvara	3.00	1.00	4.00
Dizajn	0.50	0.25	1.00

$$\times \begin{pmatrix} 1.00 & 0.33 & 2.00 \\ 3.00 & 1.00 & 4.00 \\ 0.50 & 0.25 & 1.00 \end{pmatrix} = \begin{pmatrix} 2.99 & 1.16 & 5.32 \\ 8.00 & 2.99 & 14.00 \\ 1.75 & 0.67 & 3.00 \end{pmatrix}$$

Slika 12. Prva iteracija: množenje matrice odlučivanja

Vrijednosti u recima dobivene matrice se sumiraju i normaliziraju te se tako dobiva prvi vektor prioriteta (Tablica 1. i 2.).

2,99	+	1,16	+	5,32	=	9,47
8,00	+	2,99	+	14,00	=	24,99
1,75	+	0,67	+	3	=	5,42
Ukupno:						39,88

Tablica 2. Sumiranje redova prve iteracije

$$\begin{aligned}
 9,47/39,88 &= 0,2375 \\
 24,99/39,88 &= 0,6266 \rightarrow \text{prvi vektor prioriteta} \\
 5,42/39,88 &= 0,1359
 \end{aligned}$$

**Tablica 3. Normalizacija sume redove i prvi vektor prioriteta**

Prva iteracija množi se sama sa sobom te se opet sumiraju vrijednosti njenih redaka, dobiveni se vektor stupac normalizira te to predstavlja drugi vektor prioriteta (Tablica 4.)

$$\begin{pmatrix} 2.99 & 1.16 & 5.32 \\ 8.00 & 2.99 & 14.00 \\ 1.75 & 0.67 & 3.00 \end{pmatrix} \times \begin{pmatrix} 2.99 & 1.16 & 5.32 \\ 8.00 & 2.99 & 14.00 \\ 1.75 & 0.67 & 3.00 \end{pmatrix} = \begin{pmatrix} 27.53 & 10.50 & 48.11 \\ 72.34 & 27.60 & 126.42 \\ 15.84 & 6.04 & 27.69 \end{pmatrix}$$

**Slika 13. Množenje matrice odlučivanja**

$$\begin{aligned}
 27,53 &+ 10,50 + 48,11 &= 86,14 \\
 72,34 &+ 27,60 + 126,42 &= 226,36 \\
 15,84 &+ 6,04 + 27,69 &= 49,57 \\
 \text{Ukupno:} && 362,07
 \end{aligned}$$

**Tablica 4. Sumiranje redova matrice**

$$\begin{aligned}
 86,14/362,07 &= 0,2379 \\
 226,36/362,07 &= 0,6252 \rightarrow \text{drugi vektor prioriteta} \\
 49,57/362,07 &= 0,1369
 \end{aligned}$$

**Tablica 5. Normalizacija sume redova**

Drugi je vektor potrebno oduzeti od prvog. Ako su vrijednosti dovoljno male (obično se uzima točnost na tri decimale), drugi se prihvata kao konačni vektor prioriteta kriterija. Ako nije tako, potrebno je nastaviti s iteracijama dok se ne dobije dovoljno mala razlika (Tablica 5.).

$$\begin{aligned}
 0,2375 & & 0,2379 & & -0,0004 \\
 0,6266 & - & 0,6252 & = & 0,004 \\
 0,1359 & & 0,1369 & & -0,001
 \end{aligned}$$

**Tablica 6. Izračunavanje razlike vektora prioriteta**

Iz prve matrice odlučivanja određuje se najznačajniji kriterij. Najznačajniji kriterij je onaj čija je vrijednost u konačnom vektoru prioriteta najveća (Slika 5.).

	Veličina ekrana	Učestalost kvara	Dizajn	
Veličina ekrana	1.00	0.33	2.00	0.24
Učestalost kvara	3.00	1.00	4.00	0.63
Dizajn	0.50	0.25	1.00	0.14

matrica odlučivanja    vektor prioritera

Slika 14. Odabir najznačajnijeg kriterija

Iz slike 5. vidljivo je da je najznačajniji kriterij Učestalost kvarova jer je njegova vrijednost u konačnom vektoru prioriteta najveća.

## 1.2. 2. Faza - Određivanje najznačajnije alternative

Postupak određivanja najznačajnijeg kriterija isti je i za određivanje najznačajnije alternative.

Na slici 6. prikazane su matrice odlučivanja alternativa za svaki pojedini kriterij.

	Veličina ekrana			
	Panasonic	Samsung	Sony	LG
Panasonic	1.00	5.00	4.00	3.00
Samsung	0.20	1.00	0.33	0.50
Sony	0.25	3.00	1.00	0.50
LG	0.33	2.00	2.00	1.00

Učestalost kvarova				
	Panasonic	Samsung	Sony	LG
Panasonic	1.00	0.25	0.33	0.50
Samsung	4.00	1.00	2.00	3.00
Sony	3.00	0.50	1.00	2.00
LG	2.00	0.33	0.50	1.00

Dizajn				
	Panasonic	Samsung	Sony	LG
Panasonic	1.00	0.33	0.25	2.00
Samsung	3.00	1.00	0.50	3.00
Sony	4.00	2.00	1.00	4.00
LG	0.50	0.33	0.25	1.00

Slika 15. Definiranje matrica odlučivanja za alternative

Nakon što se provedu iteracije za alternative moguće je odrediti koja je alternativa najbolja u kojem kriteriju.

$$\begin{pmatrix} 1.00 & 5.00 & 4.00 & 3.00 \\ 0.20 & 1.00 & 0.33 & 0.50 \\ 0.25 & 3.00 & 1.00 & 0.50 \\ 0.33 & 2.00 & 2.00 & 1.00 \end{pmatrix} \times \begin{pmatrix} 1.00 & 5.00 & 4.00 & 3.00 \\ 0.20 & 1.00 & 0.33 & 0.50 \\ 0.25 & 3.00 & 1.00 & 0.50 \\ 0.33 & 2.00 & 2.00 & 1.00 \end{pmatrix} = \begin{pmatrix} 3.99 & 28.00 & 15.65 & 10.50 \\ 0.65 & 3.99 & 2.46 & 1.77 \\ 1.27 & 8.25 & 3.99 & 3.25 \\ 1.56 & 11.65 & 5.98 & 3.99 \end{pmatrix}$$

Slika 16. Množenje matrice odlučivanja za alternative

3,99	+	28,00	+	15,65	+	10,50	=	58,14
0,65	+	3,99	+	2,46	+	1,77	=	8,87
1,27	+	8,25	+	3,99	+	3,25	=	16,76
1,56	+	11,65	+	5,98	+	3,99	=	23,18
Ukupno:								106,95

Tablica 7. Sumiranje redova matrice

$$58,14/106,95 = 0,5436 \rightarrow \text{vektor prioriteta}$$

$$8,87/106,95 = 0,08294$$

$$16,76/106,95 = 0,1567$$

$$23,18/106,95 = 0,2167$$

**Tablica 8. Normalizacija sume redova matrice**

Učestalost kvarova

$$\begin{pmatrix} 1.00 & 0.25 & 0.33 & 0.50 \\ 4.00 & 1.00 & 2.00 & 3.00 \\ 3.00 & 0.50 & 1.00 & 2.00 \\ 2.00 & 0.33 & 0.50 & 1.00 \end{pmatrix} \times \begin{pmatrix} 1.00 & 0.25 & 0.33 & 0.50 \\ 4.00 & 1.00 & 2.00 & 3.00 \\ 3.00 & 0.50 & 1.00 & 2.00 \\ 2.00 & 0.33 & 0.50 & 1.00 \end{pmatrix} = \begin{pmatrix} 3.99 & 0.83 & 1.41 & 2.41 \\ 20.00 & 3.99 & 6.82 & 12.00 \\ 12.00 & 2.41 & 3.99 & 7.00 \\ 6.82 & 1.41 & 2.32 & 3.99 \end{pmatrix}$$

**Slika 17. Množenje matrice odlučivanja za alternative**

3,99	+	0,83	+	1,41	+	2,41	=	8,64
20,00	+	3,99	+	6,82	+	12,00	=	42,84
12,00	+	2,41	+	3,99	+	7,00	=	25,4
6,82	+	1,41	+	2,32	+	3,99	=	14,54
							Ukupno:	91,42

**Tablica 9. Sumiranje redova matrice**

$$8,64/91,42 = 0,09451$$

$$42,84/91,42 = 0,4686 \rightarrow \text{vektor prioriteta}$$

$$25,4/91,42 = 0,2778$$

$$14,54/91,42 = 0,1590$$

**Tablica 10. Normalizacija sume redova matrice**

Dizajn

$$\begin{pmatrix} 1.00 & 0.33 & 0.25 & 2.00 \\ 3.00 & 1.00 & 0.50 & 3.00 \\ 4.00 & 2.00 & 1.00 & 4.00 \\ 0.50 & 0.33 & 0.25 & 1.00 \end{pmatrix} \times \begin{pmatrix} 1.00 & 0.33 & 0.25 & 2.00 \\ 3.00 & 1.00 & 0.50 & 3.00 \\ 4.00 & 2.00 & 1.00 & 4.00 \\ 0.50 & 0.33 & 0.25 & 1.00 \end{pmatrix} = \begin{pmatrix} 3.99 & 1.82 & 1.17 & 5.99 \\ 9.50 & 3.98 & 2.50 & 14.00 \\ 16.00 & 6.64 & 4.00 & 22.00 \\ 2.99 & 1.33 & 0.79 & 3.99 \end{pmatrix}$$

**Slika 18. Množenje matrice odlučivanja za alternative**

3,99	+	1,82	+	1,17	+	5,99	=	12,97
9,50	+	3,98	+	2,50	+	14,00	=	29,98
16,00	+	6,64	+	4,00	+	22,00	=	48,64
2,99	+	1,33	+	0,79	+	3,99	=	9,1
Ukupno:								99,69

**Tablica 11. Sumiranje redova matrice**

$12,97/99,69$	=	0,1301	
$29,98/99,69$	=	0,3007	
$48,64/99,69$	=	0,4879	→ Vektor prioriteta
$9,1/99,69$	=	0,09128	

**Tablica 12. Normalizacija sume redova matrice****1.3. 3. Faza - Određivanje konačnog rješenja (cilja)**

Kako pri donošenju ovih odluka postoji vrlo velik broj kriterija teško je svaki put provoditi ovaj postupak ručno. Zato postoje napredni računalni programi koji omogućavaju provedbu AHP metode i donošenje odluke te različiti, grafički i analitički prikaz podataka.

Također, programom se lako provodi i analiza osjetljivosti kojom se ispituju kako promjene ulaznih podataka djeluju na izlazne rezultate te laka mogućnost usporedba i provedba različitih varijanti donošenja odluka.

Konačni cilj određuje se množenjem vektora prioriteta alternativa i vektora prioriteta kriterija čime se dobiva vektor prioriteta cilja (Slika 10.). Najveća vrijednost u vektoru prioriteta cilja predstavlja konačno rješenje.

$$\begin{array}{c}
 \begin{array}{c} \text{Velčina ekrana} \\ \text{Učestalost kvara} \\ \text{Dizajn} \end{array} \\
 \begin{array}{c} \text{Panasonic} \\ \text{Samsung} \\ \text{Sony} \\ \text{LG} \end{array}
 \end{array}
 \begin{pmatrix} 0.54 & 0.09 & 0.13 \\ 0.08 & 0.47 & 0.30 \\ 0.16 & 0.28 & 0.49 \\ 0.22 & 0.16 & 0.09 \end{pmatrix}
 \times
 \begin{pmatrix} 0.24 \\ 0.63 \\ 0.14 \end{pmatrix}
 \begin{array}{c} \text{Velčina ekrana} \\ \text{Učestalost kvara} \\ \text{Dizajn} \end{array}
 =
 \begin{pmatrix} 0.21 \\ 0.36 \\ 0.28 \\ 0.16 \end{pmatrix}
 \begin{array}{c} \text{vektor prioriteta} \\ \text{alternativa} \end{array}
 \begin{array}{c} \text{vektor prioriteta} \\ \text{kriterija} \end{array}
 \begin{array}{c} \text{vektor prioriteta} \\ \text{cilja} \end{array}$$

Slika 19. Prikaz najbolje alternative

Vidljivo je kako je izabrana alternativa Samsung iako je bila najbolja samo u kriteriju Učestalost kvarova. Presudno je što je upravo taj kriterij važniji u odnosu na druga dva kriterija. I ovdje je prikazan subjektivan utjecaj donositelja odluke jer njegova procjena važnosti kriterije utječe na konačno rješenje.

#### 1.4. Problem troškova u AHP metodi

Kod kompleksnih zadataka preporučljivo je zasebno razmatrati troškove kako bi se izbjegla mogućnost dobivanja preskupe alternative s velikim brojem benefita, a cilj je dobiti jeftinu alternativu sa što je moguće većim brojem benefita. Rješenje leži u izračunu omjera benefita (B) i troškova (T), na samom kraju, prije odabira konačnog cilja. Benefiti su vrijednosti vektori prioriteta cilja za pojedinu alternativu.

	Trošak (eur)	Normalizirani trošak	Benefit/Trošak
Panasonic	1000	1000/2800=0,3571	0,21/0,3571=0,5881
<b>Samsung</b>	<b>400</b>	<b>400/2800=0,1429</b>	<b>0,36/0,1429=2,5192</b>
Sony	600	600/2800=0,2143	0,28/0,2143=1,3066
LG	800	800/2800=0,2857	0,16/0,2857=0,56
Ukupno:	2800		

Tablica 13. Izračun B/T omjera

Iz Tablice 12. vidljivo je kako najbolji (najveći) omjer benefita i troška ima Samsung, te se on predlaže za kupnju kao optimalna alternativa.

### 1.5. Konzistentnost

Konzistentnost cjelokupnog procesa provjerava se preko indeksa konzistentnosti koji mora biti manji od 10% da bi se odluka prihvatila kao valjana i konzistentna. *Konzistentnost označava dosljednost donositelja odluke u svojim odlukama i procjenama.*

U matrici odlučivanja sumiraju se stupci te se suma svakog stupca množi s konačnim redom prioriteta kako bi se izračunala konstanta  $\lambda_{\max}$  (Slika 11.)

	Veličina ekrana	Učestalost kvara	Dizajn	
Veličina ekrana	1.00	0.33	2.00	$\begin{pmatrix} 0.24 \\ 0.63 \\ 0.14 \end{pmatrix}$
Učestalost kvara	3.00	1.00	4.00	
Dizajn	0.50	0.25	1.00	
	4,50	1,58	7,00	

Slika 20. Računanje indeksa konzistentnosti

$$\lambda_{\max} = 4,50 \cdot 0,24 + 1,58 \cdot 0,63 + 7,00 \cdot 0,14 = 3,06$$

Nakon što je izračunata  $\lambda_{\max}$ , računa se indeks konzistentnosti  $CI = (\lambda_{\max} - n) / (n - 1)$ , gdje je  $n$  broj kriterija. Indeks konzistentnosti služi za izračun omjera konzistencije  $CR = CI / RI$ , gdje je  $RI$  slučajni indeks (indeks konzistencije) koji se primjenjuje samo ako je broj kriterija veći ili jednak tri.

$RI$  je tablična vrijednost i njegove vrijednosti prikazane su u Tablici 14.

n	1	2	3	5	6	7	8	9	10
RI	0	0	0,52	1,11	1,25	1,35	1,4	1,45	1,49

Tablica 14. Indeks konzistencije

U Tablici 14. prikazane su vrijednosti omjera konzistentnosti za do deset značajki.



Ako je CR manji od 0,1 tada se rješenje prihvaća kao konzistentno. U slučaju većeg broja, potrebno je preispitati odluke i procjene korisnika. Granica povoljnog indeksa konzistentnosti uzima se prema preporuci tvorca ove metode, Thomasa Saatyja.

U obrađivanom primjeru dobiveni su sljedeći rezultati:

$$CI = \frac{\lambda_{max} - n}{n - 1} = \frac{3,06 - 3}{3 - 1} = 0,03$$

$$CR = \frac{CI}{RI} = \frac{0,03}{0,52} = 0,058$$

$0,058 < 0,01 \rightarrow$  rezultati su konzistentni.